

Identifikace a modelování tkání z medicínských obrazů na základě metod shlukové analýzy s prvky umělé inteligence

Identification and Modeling of Tissues from Medical Images based on Clustering Analysis with Elements of Artificial Intelligence

Bc. Jiří Škandera

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D.

Ostrava, 2021

Abstrakt

Tato diplomová práce se zabývá metodami shlukové analýzy s prvky umělé inteligence určené k regionální segmentaci medicínských obrazů. Za pomoci segmentace jsme schopni rozčlenit a klasifikovat určitou oblast zájmu snímku, která je pro nás stěžejní. Radiodiagnostické metody dnešní doby dosahují velmi kvalitních obrazových výstupů, avšak častým jevem při získání snímku je jeho ovlivnění parazitním šumem. Metody umělé inteligence využívající evolučních a genetických algoritmů jsou v mnoha oborech využívány k řešení velmi složitých optimalizačních problémů. Převedením těchto algoritmů do kontextu obrazové segmentace jsme schopni docílit kvalitnějšího rozdělení obrazu do jednotlivých segmentů a kompenzovat tak nedostatky konvenčních metod. V této práci je zahrnuta komparační analýza jednotlivých metod v kontextu variabilních obrazových podmínek. Konkrétně se jedná o algoritmy KM, FCM, GA a PSO, které byly podrobeny důkladné analýze v testovacím a simulačním prostředí programu MATLAB. V další části práce je provedena extrakce a modelování tkání z medicínských snímků také ovlivněných parazitním šumem. Výsledkem jsou globální zhodnocení všech zmíněných algoritmů za pomoci objektivních evaluačních parametrů. V závěru jsou zhodnoceny všechny výsledné analýzy a současně bylo vytvořeno grafické uživatelské prostředí pro lepší pochopení a komparaci analyzovaných metod.

Klíčová slova

Shluková analýza, segmentace obrazu, k-means, fuzzy c-means, genetické algoritmy, optimalizace rojem částic, umělá inteligence.

Abstract

This thesis deals with methods of cluster analysis with elements of artificial intelligence designed for regional segmentation of medical images. With the help of segmentation, we are able to break down and classify a certain area of interest of the image, which is crucial for us. Today's radiodiagnostic methods achieve high-quality image outputs, but a frequent phenomenon in obtaining an image is its influence on parasitic noise. Artificial intelligence methods using evolutionary and genetic algorithms are used in many fields to solve very complex optimization problems. By converting these algorithms into the context of image segmentation, we are able to achieve a better division of the image into individual segments and thus compensate for the shortcomings of conventional methods. This work includes a comparative analysis of individual methods in the context of variable image conditions. Specifically, these are the algorithms KM, FCM, GA, PSO, which were subjected to a thorough analysis in the test and simulation environment of the MATLAB software. In the next part of the work, the extraction and modeling of tissues from medical images also affected by parasitic noise is performed. The result is a global evaluation of all mentioned algorithms using objective evaluation parameters. In the end, all the resulting analyzes are evaluated and at the same time a graphical user environment was created for a better understanding and comparison of the analyzed methods.

Key words

Cluster analysis, image segmentation, k-means, fuzzy c-means, genetic algorithm, particle swarm optimization, artificial intelligence.

Poděkování

Rád bych touto cestou poděkoval mému vedoucímu práce panu Ing. Janu Kubíčkovi, Ph.D. za jeho cenné rady, připomínky a odborné konzultace při vytváření této diplomové práce.

Obsah

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	6
SEZNAM OBRÁZKŮ	7
SEZNAM TABULEK	12
ÚVOD	13
1 SEGMENTACE OBRAZU	15
1.1 PRAHOVÁNÍ.....	15
1.2 DETEKCE HRAN.....	16
1.2.1 Detekce hran na základě první derivace.....	17
1.2.2 Detekce hran na základě druhé derivace	17
1.3 REGIONÁLNÍ TECHNIKY.....	18
1.3.1 Metoda pro narůstání oblastí.....	18
1.3.2 Metoda pro dělení oblastí	19
2 SHLUKOVÁ ANALÝZA	20
2.1 UČENÍ S UČITELEM.....	20
2.2 UČENÍ BEZ UČITELE.....	21
2.3 MÍRA PODOBNOSTI OBJEKTŮ.....	21
2.3.1 Euklidovská metrika	21
2.3.2 Manhattan metrika.....	22
2.3.3 Minkowského metrika	22
2.4 HIERARCHICKÉ METODY SHLUKOVÉ ANALÝZY	22
2.4.1 Aglomerativní metody.....	23
2.4.2 Divizní metody.....	25
2.5 NEHIERARCHICKÉ METODY SHLUKOVÉ ANALÝZY.....	25
2.5.1 Metoda k-means	26
2.5.2 Metoda fuzzy c-means	27
2.5.3 Metoda KHM (k-harmonic means).....	28
2.5.4 Metoda PAM (Partitioning Around Medoids)	29
2.5.5 Metoda CLARA (Clustering Large Applications)	30
2.6 METODY PRO OPTIMALIZACI POČTU SHLUKŮ	30
2.6.1 Metoda Elbow	30
2.6.2 Metoda Siluety	30
2.6.3 Metoda statistické mezery	31
3 REŠERŠE SEGMENTAČNÍCH TECHNIK VYUŽÍVAJÍCÍ SHLUKOVÉ ANALÝZY	32
3.1 VYHODNOCENÍ K-MEANS SHLUKOVÁNÍ ZAMĚŘENÉHO NA MEDICÍNSKÉ OBRAZY	32
3.2 EFEKTIVNÍ METODY SEGMENTACE PRO DETEKCI NÁDORU V MRI OBRAZECH	33
3.3 OBRAZOVÁ SEGMENTACE VYUŽÍVAJÍCÍ HRUBÝ FUZZY K-MEDOID ALGORITMUS	35
4 OPTIMALIZAČNÍ METODY NA BÁZI UMĚLÉ INTELIGENCE	37
4.1 GENETICKÉ ALGORITMY.....	37
4.1.1 Inicializace.....	37
4.1.2 Evaluace	38
4.1.3 Selekce.....	38
4.1.4 Křížení.....	39

4.1.5	<i>Mutate</i>	39
4.2	EVOLUČNÍ ALGORITMY	39
4.2.1	<i>PSO</i>	40
4.2.2	<i>ABC</i>	41
5	EXPERIMENTÁLNÍ ČÁST	43
5.1	NAČTENÍ OBRAZOVÉ DATABÁZE	44
5.2	IMPLEMENTACE ADITIVNÍHO ŠUMU	46
5.2.1	<i>Gaussův šum</i>	46
5.2.2	<i>Šum Salt&pepper</i>	47
5.2.3	<i>Šum Speckle</i>	48
5.3	IMPLEMENTACE SEGMENTAČNÍCH METOD	49
5.3.1	<i>K-means (KM)</i>	49
5.3.2	<i>Fuzzy c-means (FCM)</i>	51
5.3.3	<i>Particle Swarm Optimization (PSO)</i>	52
5.3.4	<i>Fitness funkce</i>	53
5.3.5	<i>Genetický algoritmus (GA)</i>	54
5.4	NASTAVENÍ TESTOVANÝCH PARAMETRŮ	55
6	EVALUAČNÍ METRIKY	59
6.1.1	<i>Korelace</i>	59
6.1.2	<i>Střední kvadratická chyba</i>	59
6.1.3	<i>SSIM</i>	60
6.1.4	<i>Jaccard koeficient</i>	60
6.1.5	<i>Dice koeficient</i>	60
7	VÝSLEDKY TESTOVÁNÍ NA REÁLNÝCH DATECH	62
7.1	VÝSLEDKY TESTOVÁNÍ SNÍMKŮ CT CÉV	62
7.2	VÝSLEDKY TESTOVÁNÍ SNÍMKŮ CT JATER	71
7.3	VÝSLEDKY TESTOVÁNÍ DATASETU MRI CHRUPAVKY	77
7.4	VÝSLEDKY TESTOVÁNÍ DATASETU MRI CÉV	78
7.5	EXTRAKCE A MODELOVÁNÍ TKÁNÍ METODAMI SHLUKOVÉ ANALÝZY	79
7.5.1	<i>Výstupy extrakce pro Gaussův šum</i>	80
7.5.2	<i>Výstupy extrakce pro Salt&pepper šum</i>	81
7.5.3	<i>Výstupy extrakce pro Speckle šum</i>	82
7.6	KOMPLEXNÍ ZHODNOCENÍ METOD	84
7.7	VÝPOČETNÍ NÁROČNOST METOD	87
8	GRAFICKÉ UŽIVATELSKÉ ROZHRAŇÍ	90
8.1	OVLÁDÁNÍ APLIKACE	91
9	DISKUSE	93
	ZÁVĚR	94
	POUŽITÁ LITERATURA	95

Seznam použitých symbolů a zkratek

Zkratka	Význam
2D	Dvojrozměrný
3D	Trojrozměrný
CORR	Korelační koeficient
CT	Výpočetní tomografie
DICE	Dice koeficient
FCM	Fuzzy c-means
GA	Genetic algorithm
GUI	Grafické uživatelské rozhraní
JACCARD	Jaccardův koeficient
KM	K-means
MRI	Magnetická resonance
MSE	Střední kvadratická chyba
PSO	Particle swarm optimization
SSIM	Structural similarity index
d	Denzita
jpg	Obrazový formát
k	Počet shluků
uint-8	Celočíselný datový typ
μ	Střední hodnota
σ	Rozptyl

Seznam obrázků

Obr. 1: Binární prahování s rozdělením na dvě segmentační třídy dle histogramu [25]	16
Obr. 2: Velikost a směr gradientu v obraze [26]	16
Obr. 3: Rozdělení hran v obraze [26].....	16
Obr. 4: Ukázka průchodu první a druhé derivace [26]	18
Obr. 5: Rozdělení neoznačené sady prvků do shluků [28]	20
Obr. 6: Dělení strojového učení [2]	21
Obr. 7: Euklidovská vzdálenost dvou prvků v prostoru [4]	22
Obr. 8: Dendogram [vlastní]	23
Obr. 9: Metoda nejbližšího souseda [14]	23
Obr. 10: Metoda nejvzdálenějšího souseda [11]	24
Obr. 11: Metoda průměrné vazby [11]	24
Obr. 12: Wardova metoda [11]	24
Obr. 13: Centroidová metoda [11]	24
Obr. 14: Znáznornění postupu tvoření shluků pomocí divizních metod [15].....	25
Obr. 15: Ukázka jednotlivých variací pro rozdělení prvků do shluků [29].....	26
Obr. 16: Jednotlivé kroky metody k-means při přerozdělování prvků do shluků [44].....	26
Obr. 17: Vlevo binární tvrdé rozhodování, vpravo měkké rozhodování na základě fuzzy logiky [30] ..	27
Obr. 18: Rozložení shluků dle metody fuzzy c-means, kde každému prvku náleží určitá míra příslušnosti ke svému shluku [16].....	28
Obr. 19: Rozdělení shluků pro metodu PAM [vlastní].....	29
Obr. 20: Grafické znázornění metod pro optimalizaci počtu shluků [24]	31
Obr. 21: Srovnání testovaných metod na MRI obrazech nádoru prsu.....	32
Obr. 22: Výsledné srovnání jednotlivých snímků jater a prsu v kontextu testovaných metod	33
Obr. 23: MRI obrazy mozku určené pro následnou segmentaci	33
Obr. 24: Srovnání výsledků segmentačních metod na obrázku Lena	36
Obr. 25: Index platnosti pro jednotlivé segmentační metody	36
Obr. 26: Vývojový diagram genetického algoritmu [vlastní].....	37
Obr. 27: Ruletová selekce [37]	38
Obr. 28: Turnajová selekce [37]	39
Obr. 29: Znáznornění křížení a mutace na binárních hodnotách [vlastní]	39
Obr. 30: Aktualizace jednotlivých částic zobrazená vektorem [41]	40
Obr. 31: Nejčastěji používané topologie PSO: a) kruhová, b) globální, c) Von-Neumanova [40].....	41

Obr. 32: Znázornění funkce algoritmu ABC na včelím roji [38]	41
Obr. 33: Diagram reprezentující princip celkového testování [vlastní].....	43
Obr. 34: Ukázka datasetu MRI chrupavky [vlastní]	44
Obr. 35: Ukázka datasetu CT jater [vlastní].....	44
Obr. 36: Ukázka datasetu CT cév [vlastní].....	45
Obr. 37: Ukázka datasetu MRI cév [vlastní]	45
Obr. 38: Aplikace Gaussova šumu na medicínské snímky. Zleva: nativní snímky; $\mu=0,1$, $\sigma^2=0,01$; $\mu=0,2$, $\sigma^2=0,01$ [vlastní]	47
Obr. 39: Aplikace Salt&pepper šumu na medicínské snímky. Zleva: nativní snímek; $d=0,1$; $d=0,2$ [vlastní]	48
Obr. 40: Aplikace Speckle šumu na medicínské snímky. Zleva: nativní snímek; $\sigma=0,1$; $\sigma=0,2$ [vlastní].....	49
Obr. 41: Algoritmus metody k-means [vlastní]	50
Obr. 42: Vlevo nativní snímek, vpravo segmentovaný snímek MRI cév metodou k-means pro 3 shluky [vlastní]	50
Obr. 43: Segmentovaný snímek MRI cév metodou FCM. Zleva nativní snímek; segmentovaný snímek pro 3 shluky; graf míry příslušnosti pixelů ke shlukům [vlastní]	51
Obr. 44: Algoritmus metody FCM [vlastní].....	52
Obr. 45: Segmentovaný snímek CT cév metodou PSO zleva pro 3; 7 shluků [vlastní]	52
Obr. 46: Algoritmus metody PSO [vlastní]	53
Obr. 47: Grafické znázornění hodnoty fitness funkce v závislosti na počtu iterací, metoda PSO [vlastní]	54
Obr. 48: Algoritmus metody GA [vlastní]	54
Obr. 49: GA segmentace CT cév s nastavením pro 5 a 10 shluků. Velikost populace: 50; počet generací: 20 [vlastní]	55
Obr. 50: Grafické znázornění hodnoty fitness funkce v závislosti na počtu generací, metoda GA [vlastní]	55
Obr. 51: Nastavení GA testovaných parametrů pro Gaussův šum, dataset 1 a 3 shluky [vlastní]	57
Obr. 52: Vlevo parametry funkce metody PSO, vpravo metody GA [vlastní]	58
Obr. 53: Grafická ukázka principu výpočtu Jaccard koeficientu [47]	60
Obr. 54: Grafická ukázka principu výpočtu Dice koeficientu [47]	61
Obr. 55: Ukázka implementace Gaussova šumu na snímek CT cév. Zleva nativní snímek; zašuměný snímek $\mu=0,1$, $\sigma^2=0,01$ [vlastní].....	62

Obr. 56: Ukázka segmentačních metod pro 5 shluků, Gaussův šum $\mu=0,1$, $\sigma^2=0,01$. Zleva metoda: KM; FCM; GA [vlastní]	63
Obr. 57: Analýza robustnosti CT cév pro Gaussův šum, 10 shluků a metody KM, FCM a GA [vlastní] .	63
Obr. 58: Ukázka segmentace pro 5 shluků, 100 populace a Gaussův šum. Zleva: zašuměný snímek $\mu=0,2$, $\sigma^2=0,01$; segmentace metodami KM; FCM; GA [vlastní]	64
Obr. 59: Analýza robustnosti snímků CT cév pro Salt&pepper šum, 10 shluků a metody KM,FCM a GA [vlastní]	64
Obr. 60: Ukázka segmentačních metod pro 5 shluků, 100 populace a Salt&pepper šum. Zleva: Zašuměný snímek $d=0,2$; segmentace KM; segmentace FCM; segmentace GA [vlastní]	65
Obr. 61: Analýza robustnosti snímků CT cév, Speckle šum, 10 shluků a metody KM,FCM a GA [vlastní]	65
Obr. 62: Analýza robustnosti snímků CT cév dle počtu shluků, pro Speckle šum a metodu GA [vlastní]	66
Obr. 63: Ukázka snímků CT cév se Speckle šumem. Horní řada snímků reprezentuje zleva nativní snímek; segmentace pro 3 shluky; 5 shluků, dolní řada segmentaci pro 7; 10; 12 shluků [vlastní]	67
Obr. 64: Analýza robustnosti snímků CT cév dle populace, pro Gaussův šum, 3 shluky a metodu GA [vlastní]	67
Obr. 65: Závislost fitness funkce na počtu generací pro nastavení populace a generace 20 [vlastní] .	68
Obr. 66: Závislost fitness funkce na počtu generací pro nastavení populace 100 a generace 20 [vlastní]	68
Obr. 67: Analýza robustnosti snímků CT cév dle dodatečného nastavení pro Gaussův šum, 12 shluků, 50 populace a metody KM, FCM a GA [vlastní]	69
Obr. 68: Ukázka snímku CT jater. Zleva nativní snímek; zašuměný snímek Gaussovým šumem o intenzitě $\mu=0,15$, $\sigma^2=0,01$ [vlastní]	71
Obr. 69: Ukázka snímků pro Gaussův šum o intenzitě $\mu=0,15$, $\sigma^2=0,01$. Zleva metoda KM; FCM; GA [vlastní]	71
Obr. 70: Analýza robustnosti snímků CT jater pro Gaussův šum, 3 shluky a metody KM,FCM a GA [vlastní]	72
Obr. 71: Ukázka selekce obrátle ze snímku CT jater ovlivněného šumem. Zleva nativní snímek; zašuměný snímek Gaussovým šumem $\mu=0,1$, $\sigma^2=0,01$; segmentovaný snímek metodou GA pro 3 shluky [vlastní]	72

Obr. 72: Analýza robustnosti snímků CT jater pro šum Salt&pepper, 3 shluky a metody KM,FCM a GA [vlastní]	73
Obr. 73: Analýza robustnosti snímků CT jater pro šum Speckle, 3 shluky a metody KM,FCM a GA [vlastní]	74
Obr. 74: Analýza robustnosti snímků CT jater dle počtu shluků, pro Salt&pepper šum a metodu KM [vlastní]	74
Obr. 75: Analýza robustnosti snímků CT jater dle počtu shluků, pro Salt&pepper šum a metodu GA [vlastní]	75
Obr. 76: Srovnání nastavení počtu shluků pro metodu GA a Gaussův šum o intenzitě $\mu=0,1$, $\sigma^2=0,01$. Zleva nastavení pro 3; 5; 7; 10 shluků [vlastní]	75
Obr. 77: Analýza robustnosti snímků CT jater dle dodatečného nastavení pro Salt&pepper šum, 10 shluků, 150 populace a metody KM,FCM a GA [vlastní]	76
Obr. 78: Ukázka snímku MRI chrupavky. Zleva zašuměný snímek Gaussovým šumem $\mu=0,2$, $\sigma^2=0,01$; segmentované snímky metodou FCM pro 3; 5; 7 shluků [vlastní]	77
Obr. 79: Ukázka snímku MRI cév. Zleva zašuměný snímek Gaussovým šumem $\mu=0,1$, $\sigma^2=0,01$; segmentované snímky metodou GA pro 3; 5; 7 shluků [vlastní]	78
Obr. 80: Ukázka segmentovaných snímků metodou PSO pro extrakci oblasti zájmu [vlastní]	79
Obr. 81: Extrakce a modelování tkání, vlevo kalcifikace cév, uprostřed cévní řečiště hlavy a krku, vpravo cévní řečiště cév oblasti pánve [vlastní]	80
Obr. 82: Ukázka výstupu extrakce pro Gaussův šum a metodu KM. Zleva nastavení: $\sigma^2=0,01$, $\mu=0,1$; $\sigma^2=0,01$, $\mu=0,2$; $\sigma^2=0,01$, $\mu=0,35$ [vlastní]	80
Obr. 83: Analýza robustnosti extrahovaných snímků pro Gaussův šum [vlastní]	81
Obr. 84: Ukázka výstupu extrakce pro Salt&pepper šum a metodu PSO. Zleva nastavení: $d=0,1$; $d=0,2$; $d=0,35$ [vlastní]	81
Obr. 85: Analýza robustnosti extrahovaných snímků pro Salt&pepper šum [vlastní]	82
Obr. 86: Ukázka výstupu extrakce pro Speckle šum a metodu PSO. Zleva nastavení: $\sigma^2=0,1$; $\sigma^2=0,2$; $\sigma^2=0,35$ [vlastní]	83
Obr. 87: Analýza robustnosti extrahovaných snímků pro Speckle šum [vlastní]	83
Obr. 88: Graf závislosti fitness hodnoty na počtu generace u metody PSO (vlevo) a GA (vpravo) s nastavením populace 100 a generace/iterace 20 [vlastní]	84
Obr. 89: Analýza robustnosti datasetů pro Gaussův šum pro všechny metody a 10 shluků [vlastní] ..	84

Obr. 90: Analýza robustnosti jednotlivých datasetů v kontextu Salt&pepper šumu pro všechny metody a 7 shluků [vlastní]	85
Obr. 91: Analýza robustnosti jednotlivých datasetů v kontextu Speckle šumu pro všechny metody a 5 shluků [vlastní]	85
Obr. 92: Analýza robustnosti jednotlivých metod v kontextu Gaussova šumu pro všechny datasety a 7 shluků [vlastní]	86
Obr. 93: Analýza robustnosti jednotlivých metod v kontextu Salt&pepper šumu pro všechny datasety a 7 shluků [vlastní]	86
Obr. 94: Analýza robustnosti jednotlivých metod v kontextu Speckle šumu pro všechny datasety a 7 shluků [vlastní]	87
Obr. 95: Blokový diagram funkcí grafického uživatelského prostředí [vlastní]	90
Obr. 96: Grafické uživatelské rozhraní [vlastní]	91
Obr. 97: Dialogové okno umožňující výběr snímku z počítače [vlastní]	91
Obr. 98: Ukázka načtení a zašumění snímku [vlastní]	92
Obr. 99: Výsledky všech segmentací spolu se zobrazením evaluačních parametrů [vlastní]	92

Seznam tabulek

Tabulka 1: Vlevo tabulka srovnávající metody k-means a optimalizovaný k-means, uprostřed srovnávající metody FCM a optimalizovaný FCM a vpravo metody optimalizovaný k-means a FCM..	34
Tabulka 2: Vyhledávající čas pro optimalizovanou metodu k-means a FCM	35
Tabulka 3: Popis obrazové databáze [vlastní]	44
<i>Tabulka 4: Nastavení intenzity šumových generátorů [vlastní]</i>	<i>46</i>
Tabulka 5: Nastavení testovaných parametrů pro všechny metody [vlastní].....	56
Tabulka 6: Výsledky hodnot evaluačních parametrů pro dataset 1 a Gaussův šum [vlastní]	70
Tabulka 7: Výsledky hodnot evaluačních parametrů pro dataset 3 a Salt&pepper šum [vlastní]	76
Tabulka 8: Výpočetní náročnost metod KM a FCM pro všechny typy šumů [vlastní]	87
Tabulka 9: Výpočetní náročnost metody GA s nastavením 1, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]	88
Tabulka 10: Výpočetní náročnost metody GA s nastavením 2, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]	88
Tabulka 11: Výpočetní náročnost metody GA s nastavením 2, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]	88

Úvod

Do nedávna byla medicínská obrazová data analyzována pouhým okem odborníka. V dnešní rychle rozvíjející se době postupně člověka nahrazují automatické segmentační techniky a metody umělé inteligence, které dosahují velmi často kvalitnějších výsledků než pouhé lidské oko. To dává velký náskok k časnému odhalení patologických změn, které jsme schopni zachytit z obrazových dat radiodiagnostických metod. U všech segmentačních metod využívaných v medicíně je vždy kladen velký důraz na kvalitu a přesnost výsledku, neboť jen sebemenší chyba či odchylka může znamenat razantní změnu v přístupu k léčbě pacienta, čímž ho můžeme ohrozit i na životě.

Diplomová práce se zabývá metodami regionální segmentace, které jsou schopny rozčlenit obraz do skupiny regionů, kde každý z regionů reprezentuje určitou část obrazu, kterou jsme schopni identifikovat, spočítat její velikost či extrahovat. Příkladem může být snímek nádoru mozku, který po segmentaci do dvou separátních regionů bude na výstupu tvořit nádor a pozadí snímku. V práci je využíváno metod shlukové analýzy, které jsou jedním z hlavních pilířů rozpoznávání a segmentace. Zohledněny jsou zde především nehierarchické metody, které přerozdělují neoznačené sady prvků, v našem případě obrazové pixely do shluků, čímž dávají výrazně lepší možnost oddělit oblast zájmu od pozadí či parazitního šumu.

Dalším odvětvím jsou optimalizační metody s prvky umělé inteligence. Jedná se především o evoluční a genetické algoritmy, které nacházejí inspiraci v dlouhodobém evolučním či genetickém procesu živočichů. Pro možnost implementovat tyto metody v kontextu regionální segmentace byly jednotlivé procesy matematicky popsány a dimenzovány na obrazovou segmentaci. Genetický algoritmus (GA) používá operátory křížení, selekce či mutace, díky kterým je schopen ze vstupní sady dat definovat velmi přesné výsledné řešení. Zástupcem evolučních algoritmů je PSO (Particle Swarm Optimization) pracující na principu roje částic. Jednotlivé roje jsou nejčastěji inspirovány hejnem ptáků či ryb, kde u každého roje definujeme a upravujeme rychlost a polohu všech částic. Algoritmy jsou ohodnoceny na základě každé iterace dle výpočtu fitness funkce, což je funkce kalkuluující rozptyl mezi jednotlivými pixely a přiděleným shlukem. Pokud se součet všech rozptylů minimalizuje, dosahujeme kvalitnějšího výsledku.

Cílem práce je komparativní analýza zmíněných metod shlukové analýzy v porovnání s optimalizačními algoritmy využívající prvky umělé inteligence. Analýza je provedena v kontextu variabilních obrazových podmínek, které jsou dynamicky měněny na základě implementace parazitního šumu. Práce je členěna na teoretickou a praktickou část. První z částí obsahuje především úvod do současné problematiky segmentace obrazu. V první kapitole jsou okrajově zmíněny metody využívané pro segmentaci prahování a detekce hran. Druhá kapitola je již věnována samotné shlukové analýze, kde je v počátku rozebrána problematika strojového učení a míra podobnosti objektů popisující metriky vzdálenosti. Následuje hlavní rozdělení metod shlukové analýzy, přičemž v této práci nachází své uplatnění metody nehierarchické, a to především k-means (KM) a fuzzy c-means (FCM). Třetí kapitola obsahuje stručnou rešeršní část ukazující na současnou problematiku regionální segmentace za pomoci shlukové analýzy jak konvenčními, tak moderními přístupy s prvky umělé inteligence. Poslední čtvrtá kapitola patří k teoretické části obsahuje detailní popis vnitřní struktury optimalizačních algoritmů GA a PSO.

Praktická část počínaje pátou kapitolou popisuje načtení obrazové databáze spolu s následnou implementací parazitních šumů variabilních intenzit. V další fázi jsou podrobně popsány optimalizační algoritmy spolu s reálnými obrazovými výstupy a grafy ukazující minimalizaci fitness funkce u metod GA a PSO.

Kapitola 6 a 7 se věnuje samotnému vyhodnocení a analýze výsledků jednotlivých segmentací, a to na základě objektivních evaluačních parametrů, kterým je věnován popis v kapitole číslo 6. Po vyhodnocení všech segmentací přichází na řadu zhodnocení, které je realizováno na základě zprůměrování několika výsledných segmentací, které jsou následně graficky i slovně interpretovány v kapitole 7.

Poslední kapitola 8 je zaměřena na tvorbu grafického uživatelského prostředí, které bylo realizováno pro zjednodušení a lepší pochopení dané problematiky. V prostředí je možné načíst snímek, aplikovat parazitní šum a následně využít některou ze čtyř segmentačních technik. Výsledkem je model segmentace a evaluační parametry, které je možné exportovat a uložit pro další zpracování.

1 Segmentace obrazu

Pomocí segmentačních technik jsme schopni vytvořit či separovat část, objekt či entitu z daného obrazu. Rozpoznávání vzorů a analýza obrazu jsou základními kroky k segmentaci. Segmentace má za úkol provést dekompozici obrazu do dílčích částí, které jsou si vzájemně podobné. Výstupem je segmentační mapa regionů, která reprezentuje a lokalizuje objekty v obraze. Důležitým parametrem segmentace je kvalita vstupního obrazu, neboť výsledky segmentace mají radikální dopad na jeho následnou analýzu. Často tedy ještě před samotnou segmentací je obraz filtrován, a to pro zvýšení homogenity jasové stupnice. Existuje mnoho algoritmů a základních metod dostupných pro segmentaci obrazu, ale stále je potřeba vybrat a optimalizovat zvolenou metodu pro výchozí úlohu.

Segmentace obrazu je interpretována segmentační mapou, která se skládá z jednotlivých tříd, do kterých patří právě rozdělené množiny pixelů. Komplexně se tyto třídy označují unikátním číslem, tzv. labelem (popiskem). V rámci segmentace a označení dle jednotlivých labelů rozdělujeme metody na binární, kde dochází k rozdělení do dvou segmentačních tříd: 0 – pozadí, 1 – objekt a multisegmentace obsahující více než tři regiony, kde každý z nich je popsán jedinečným labelem.

Pro uvedení do celkové problematiky jsou zde zmíněny pouze základní metody segmentace obrazu vyjma metod shlukové analýzy, které jsou stěžejní pro tuto diplomovou práci a je jim věnována druhá kapitola [1].


1.1 Prahování

Jedním ze základních způsobů segmentace obrazu je metoda prahování, která spadá do skupiny jasově orientovaných segmentací. Nachází velmi účinný způsob segmentace u obrazů se světlými objekty na ponurém pozadí. Prahová hodnota transformuje víceúrovňový obraz na binární, tj. zvolí konkrétní prahovou hodnotu, aby se obrazové pixely rozdělily na několik oblastí a oddělily objekty od pozadí, viz Obr. 1.

$$g(i, j) = \begin{cases} 0, & \text{pro } f(i, j) \in D \\ 1, & \text{jinak} \end{cases} \quad (1.1)$$

Vzorec (1.1) ukazuje výpočet, kde $g(i, j)$ je výstupní hodnota prahování a D je množina jasových hodnot. Práh je nejčastěji určován z histogramu, problémem je však, kde v histogramu zvolit daný práh, aby došlo ke správnému rozdělení pixelů. Základní metodou pro automatické určení prahu je zvolení minimální hodnoty funkce mezi dvěma dostatečně vzdálenými maximy. Segmentace se získá změnou všech pixelů s intenzitou větší, než je prahová hodnota do jedné třídy a všech ostatních pixelů do třídy druhé.


Mezi sofistikovanější metody prahování se řadí metoda Otsu, která je schopná automaticky vyhledat optimální práh dle histogramu. Výchozím řešením je nalezení takového prahu, který minimalizuje vážený rozptyl dvou tříd jasů, tzn. oddělení pozadí a popředí obrazu.



Obr. 1: Binární prahování s rozdělením na dvě segmentační třídy dle histogramu [25]


1.2 Detekce hran

Detekce hran je základním nástrojem používaným ve většině aplikací pro zpracování obrazu, a to k získávání informací pro následnou extrakci prvků a segmentaci objektů. Principem je detekce místa tzv. hrany, kde dochází k náhlé změně jasové intenzity sousedících pixelů. Následně jsme schopni detekovat obrysy a hranice mezi objekty a pozadím v obraze. Hranu dělíme dle tvaru na skokovou, střeškovou, tenkou linii a zašuměnou, viz Obr. 3. Hranových detektorů existuje nespočetně mnoho, primárně je však rozdělujeme na metody využívající první derivaci nebo druhou derivaci jasové funkce.



Obr. 2: Velikost a směr gradientu v obraze [26]

Důležitou operací při implementaci hranových detektorů je obrazová konvoluce. Původní obraz převedený do maticové formy je vynásoben jinou maticí, tzv. konvolučním jádrem, což je jádro o velikosti matice obvykle od 2×2 do 6×6 buněk. Následně je toto konvoluční jádro posouváno po celém obraze a vždy jsou násobeny hodnoty jádra a hodnoty místa v obraze, nad kterým se toto jádro zrovna nachází. V neposlední řadě jsou tyto násobky sečteny a zapsány do právě zpracované buňky. Konvoluce je iteračně opakována, dokud neprojde celou obrazovou maticí.



Obr. 3: Rozdělení hran v obraze [26]

1.2.1 Detekce hran na základě první derivace

V částech obrazu, kde nedochází ke skokové změně jasové stupnice, je první derivace rovna nule. Naopak v místech, kde dochází k razantní změně jasu, je hodnota první derivace dána právě velikostí změny hrany v obraze. Velikost a směr změny jasové funkce jsou dány vektorem, který se nazývá gradient. Směr hrany je vždy kolmý ke gradientu a velikost hrany je úměrná velikosti gradientu, viz Obr. 2. Výsledný gradient hranového detektoru nejčastěji získáme použitím takových operátorů, které jsme schopni vyjádřit za pomoci konvolučního jádra [26].

Velikost gradientu:

$$|\nabla g(i,j)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2} \quad (1.2)$$

Směr gradientu:

$$\psi = \arctan\left(\frac{\frac{\partial g}{\partial y}}{\frac{\partial g}{\partial x}}\right) \quad (1.3)$$

kde ∂x představuje horizontální a ∂y vertikální gradient.

Robertsův hranový detektor


Ačkoliv hranových detektorů na základě první derivace existuje mnoho, v této práci bude zmíněn jako příklad pouze jeden z hlavních a nejstarších detektorů, Robertsův. Detektor pracuje na principu výpočtu difference ve dvou na sobě kolmých diagonálních směrech a pracuje s maticí o velikosti 2 x 2. Častým problémem detektoru bývá nízká odolnost vůči šumu, neboť využívá malé množství pixelů pro odhad gradientu [26].

Tvar konvolučního jádra:

$$k_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad k_2 = \begin{bmatrix} 1 & 1 \\ -1 & 0 \end{bmatrix}$$

1.2.2 Detekce hran na základě druhé derivace

Hrany můžeme najít i pomocí průchodů druhé derivace nulou, tzv. zero-crossings. Pokud stanovíme místo, kde se nachází maximum první derivace, zároveň definujeme místo derivace druhé, a to tam, kde dochází k protnutí nulové hodnoty, viz Obr. 4. Spolehlivost této metody je určitě vyšší než u detekce hran na základě derivace první, ale na druhou stránku jsou tyto metody více náchylné na parazitní šum [26].



Obr. 4: Ukázka průchodu první a druhé derivace [26]

Laplaceův operátor

Využívá se hlavně k ostření obrazu, neboť zdůrazňuje oblasti s vysokými frekvencemi. Metoda představuje pouze skalární součin, viz. Vzorec (1.4). Dochází tedy pouze k určení velikosti hrany, nikoli však jejího směru. U monotónní rostoucí funkce je Laplaceán nulový tam, kde v příslušném okolí je velikost gradientů co nejvyšší, tedy průchod druhé derivace nulou [27].

Vztah pro Laplaceův operátor:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}, \quad (1.4)$$

kde ∂x představuje horizontální a ∂y vertikální gradient.

Konvoluční jádro:

$$k_1 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad k_2 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

1.3 Regionální techniky

Metody segmentace založené na regionech jsou metody, které segmentují obraz do různých oblastí, které mají podobné charakteristiky. Na tomto principu jsou založeny dvě následující základní techniky.

1.3.1 Metoda pro narůstání oblastí

Metody segmentace založené na narůstání regionů jsou metody, do kterých se segmentuje obraz různé oblasti založené na rozrůstání počátečních pixelů. Tyto pixely lze vybrat ručně na základě předchozí znalosti nebo automaticky na základě konkrétní aplikace. Pak je narůstání oblastí řízeno konektivitou mezi pixely a pomocí předchozí znalosti problému. Regiony se společnými znaky jsou nadále slučovány za cílem vytvoření co největší oblasti.


1.3.2 Metoda pro dělení oblastí

Další možností je zvolení opačného postupu při zpracování než u metody předchozí. Obraz je brán jako jedna velká oblast, která je postupně dělená do co nejvíce menších a zároveň nezávislých oblastí. Jde o přidání chybějících hran tím, že od sebe separujeme regiony pixelů, které náležejí do rozdílných oblastí zájmu obrazu.

2 Shluková analýza

Shlukování dat je proces detekce a rozdělení souboru neoznačených prvků, kde prvky jedné skupiny, tzv. shluku, vykazují mezi sebou maximální signifikantní podobnost, na rozdíl od prvků mimo tuto skupinu, kde je tato podobnost minimální, viz Obr. 5. Shlukování se řadí mezi průzkumnou analýzu dat, uživatel proto nemusí mít žádné nebo jen minimální informace o parametrech výsledné analýzy. V typických příkladech je výstupem analýzy počet shluků, jejich pozice, velikost, tvar a hustota rozdělení prvků.

Uplatnění se nachází v mnoha oblastech jako je lékařský výzkum, statistika, psychologie, ekonomie, a především segmentace obrazu. Metody shlukové analýzy se dynamicky liší, a to v závislosti na použité metodě, objektivní funkci či způsobu vyjádření míry podobnosti mezi jednotlivými prvky v souboru. Algoritmy shlukování lze obecně rozdělit na hierarchické a nehierarchické metody [9, 28].



Obr. 5: Rozdělení neoznačené sady prvků do shluků [28]

Jedním ze základních pilířů inteligence je schopnost učit se novým věcem, shluková analýza spadá do skupiny metod strojového učení, což je oblast, která se v poslední době velmi dynamicky rozvíjí a dává tím prostor zlepšovat výsledné úlohy v oblastech umělé inteligence.


Strojové učení se zabývá principy, které umožňují danému výpočetnímu systému adaptovat se na okolní prostředí za pomoci metod učení. V praxi se může jednat o algoritmus, který je schopen se přizpůsobit a naučit zpracovávat úkoly z dané sady dat na rozdíl od pouhého naprogramování. Pracujeme zde s dvěma hlavními kategoriemi algoritmů strojového učení, a to učení s učitelem a učení bez učitele, kde spadá i právě zmíněná shluková analýza [1, 9, 13].

2.1 Učení s učitelem

Algoritmy založené na principu učení s učitelem lze chápat jako proces, který se snaží přeměnit zadaný vstup na požadovaný výstup, kde s každou další přeměnou dochází ke zdokonalení algoritmu. Obvykle se na začátku snaží algoritmus porozumět, jak jsou analyzovaná data klasifikována. Následně dochází k nalezení vzorů v datech, které lze použít k realizaci analytického procesu, který je závislý na vstupních i výstupních datech. Příkladem aplikace může být rozlišení několika tisíc zvířat na základě písemných a obrazových popisů. Učení s učitelem dělíme dále na klasifikaci a regresi [2, 3].

2.2 Učení bez učitele

Využití nachází hlavně u velkých skupin neoznačených dat, které je zapotřebí klasifikovat do požadovaných podskupin. V tomto případě je výuková sada příkladů přivedena pouze na výstup, není již však požadována na výstupu jako u učení s učitelem. Sem patří shluková analýza, která je schopna rozdělit jednotlivé pixely obrazu na základě jejich podobnosti, což je hlavním tématem této diplomové práce a bude rozebráno v následujících kapitolách [2, 3].



Obr. 6: Dělení strojového učení [2]

2.3 Míra podobnosti objektů


Pro zjištění vzájemných vztahů či podobnosti mezi prvky zkoumaného souboru jsou vyčleněny metriky podobnosti, které jsou základními částmi většiny shlukovacích algoritmů. Identickým parametrem pro všechny metriky je, že prvky dosahující maximální podobnosti mají vzdálenost nulovou, naopak prvky neidentické mají mezi sebou vzdálenost největší. Volba typu metriky záleží především na typu řešené úlohy a také na rozložení dat v souboru [7].

Metriky vzdálenosti musí dodržovat následující podmínky:

- pokud jsou prvky stejné, vzdálenost je mezi nimi nulová;
- pokud $x=y$, pak $D(x,y)=0$, platí, že mezi rozdílnými objekty je vzdálenost kladná;
- pokud $x \neq y$, pak $D(x,y) > 0$, platí, že vzdálenost objektu x od y je stejná jako y od x ;
- pokud máme součet $D(x,y) + D(y,x)$, musí být vždy větší nebo roven $D(x,z)$, neboť zde platí trojúhelníková nerovnost [4, 5, 6].

2.3.1 Euklidovská metrika

Představuje vzdálenost dvojice prvků v prostoru založenou na Pythagorově větě, viz vzorec (2.1), kde x a y reprezentují dva srovnávané body v obraze a D_1 je jejich výsledná vzdálenost. Jedná se o základní metriku používanou v mnoha odvětvích shlukové analýzy, zároveň je jádrem metody k-means, kde slouží k nalezení co nejbližších a nejpodobnějších prvků. Graficky Euklidovskou metriku znázorňuje Obr. 7 [5, 7].



Obr. 7: Euklidovská vzdálenost dvou prvků v prostoru [4]

$$D_1(x, y) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad (2.1)$$

2.3.2 Manhattan metrika

Metrika podobná Euklidovské, avšak méně náročná na výpočetní kapacitu, často využívána u metody fuzzy c-means. Jako názorný příklad výpočtu vzdálenosti je předkládána jízda automobilem městem s pravoúhlými ulicemi, proto má také někdy název city-block metrika. Výpočet je znázorněn vzorcem (2.2), kde x a y reprezentují dva srovnávané body v obraze a D_2 je jejich výsledná vzdálenost [4, 5].

$$D_2(x, y) = \sum_{i=1}^m |x_i - y_i| \quad (2.2)$$

2.3.3 Minkowského metrika

Minkowského metrika kombinuje dvě metody výpočtu vzdálenosti, a to Euklidovskou a manhattanskou. Důležité je zde zmínit, že se zvyšujícím se koeficientem umocňování se zvyšuje významnost rozdílů, viz vzorec (2.3), kde x a y reprezentují dva srovnávané body v obraze a D_3 je jejich výsledná vzdálenost. V praxi to znamená, že pokud metrika dosahuje většího důrazu na rozdíly mezi prvky, je to zapříčiněné vyšší mocninou při výpočtu metriky [4, 5].


$$D_3(x_1, x_2) = \left[\sum_{i=1}^m |x_i - y_i|^\lambda \right]^{1/\lambda} \quad (2.3)$$

2.4 Hierarchické metody shlukové analýzy

Hierarchické metody pro shlukování přistupují k problému na základě vývoje binární stromové datové struktury zvané dendrogram. Jednotlivé shluky na různých úrovních dendrogramu jsou členěny dle jejich četnosti, viz Obr. 8, kde každý z uzlů dendrogramu vyobrazuje právě jeden shluk.

Vertikální směr představuje vzdálenost mezi jednotlivými shluky. Po prvotním vytvoření dendogramu lze automaticky zvolit řešení pro stejnou datovou sadu, aniž by bylo nutné algoritmus znovu spustit. Tyto algoritmy jsou hojně používány v široké škále aplikací především kvůli jejich jednoduchosti a snadnosti implementace ve srovnání s nehierarchickými algoritmy [8, 9].

Shlukování lze dosáhnout dvěma různými způsoby, a to shlukováním zdola nahoru a shora dolů. Ačkoli oba tyto přístupy využívají koncept shlukování dat, mohou přinést zcela odlišné sady výsledků v závislosti na kritériu použitém během procesu shlukování. Na základě, zda je toto hierarchické znázornění vytvořeno shora dolů nebo zdola nahoru, lze tato zobrazení považovat za aglomerativní nebo divizní metody [7, 10].



Obr. 8: Dendogram [vlastní]

2.4.1 Aglomerativní metody

V těchto metodách se využívá přístupu zdola nahoru, kde začínáme s jednotlivými prvky a postupně je slučujeme ve shluky, abychom vytvořili dendogram. Slučování je realizováno na základě podobnosti mezi jednotlivými prvky, které spojujeme po dvojicích, a to v pořadí od shluků s nejvyšší podobností k podobnosti nejnižší. Výsledkem aglomerativní metody je právě jeden shluk. Aglomerativní metody disponují u menších datových souborů kvalitními a rychlými výsledky, avšak u středních a velkých souborů jsou již nedostačující [12, 13].

Existuje řada možností jak mohou být tyto jednotlivé shluky sloučeny, což poskytuje různé kompromisy mezi kvalitou a efektivitou algoritmu. Jednotlivý zástupci aglomerativních metod, jako jsou metoda nejbližšího souseda, nejvzdálenějšího souseda či metoda průměrné vazby, jsou rozebrány podrobněji níže.

Metoda nejbližšího souseda


Prvky jednotlivých shluků jsou libovolně slučovány na základě jejich minimální vzdálenosti. Takto nalezené prvky se spojují co možná nejkratší cestou, viz Obr. 9 [18].



Obr. 9: Metoda nejbližšího souseda [14]

Metoda nejvzdálenějšího souseda

Prvky jednotlivých shluků jsou zde na rozdíl od metody předchozí slučovány dle jejich maximální vzdálenosti, viz Obr. 10. Důležitým aspektem je, že pokud se v datovém souboru nachází mnoho odlehklých hodnot, je tato metoda nevhodná, protože může docházet ke zkreslení výsledku shlukování [18].



Obr. 10: Metoda nejvzdálenějšího souseda [11]

Metoda průměrné vazby


Jednotlivé prvky shluku jsou slučovány na základě průměrné vzdálenosti mezi prvky vždy rozdílného shluku, viz Obr. 11. Shluky s minimální průměrnou vzdáleností jsou ty, které vykazují nejvyšší signifikantní podobnost [18].



Obr. 11: Metoda průměrné vazby [11]

Wardova metoda


Vzdálenost mezi jednotlivými shluky je definována jako ztráta informace při vytvoření nových shluků. Slučovány jsou tedy pouze shluky, které vykazují co možná nejvyšší homogenitu, aby variace uvnitř sloučeného shluku vzrůstaly co nejméně, viz Obr. 12 [18].



Obr. 12: Wardova metoda [11]

Centroidová metoda

Metoda pracuje na základě výpočtu vzdálenosti, a to mezi jednotlivými těžišti shluků. Následujícím krokem je spojení shluků od minimálních vzdáleností mezi těžišti ke vzdálenostem maximálním. Výpočet je realizován Euklidovskou metrikou vzdálenosti. Znázornění metody je na Obr. 13 [15].



Obr. 13: Centroidová metoda [11]


2.4.2 Divizní metody

Princip je založen na celistvé množině prvků tvořící jeden hlavní shluk, který je následně dělen na dílčí shluky a tím je tvořen hierarchický systém, viz Obr.14. V každém kroku vždy dochází k rozdělení aktuálního shluku na dvojici menších shluků tak, aby v závěru byly všechny shluky jednoprvkové.

Hlavní nevýhoda těchto metod je zdoluhavé nalezení optimálního řešení. Další z nevýhod je vysoká náročnost díky exponenciální časové složitosti, tudíž jsou metody tedy vhodné pouze pro malé datové soubory [13, 14, 18].

MacNaughton–Smithova metoda

Za pomoci středních vzdáleností dochází k výběru prvku z daného shluku, následně je vytvořen nový shluk, a to na základě rozdílu středních vzdáleností prvků z původního a nového shluku. V následujícím kroku se prvek přiřadí do nového shluku. Metoda disponuje sníženou časovou náročností, avšak na druhou stránku výsledné rozdělení shluků nebývá optimální, proto ve většině případů bývají upřednostňovány metody aglomerativní [18].




Obr. 14: Znáznornění postupu tvoření shluků pomocí divizních metod [15]

2.5 Nehierarchické metody shlukové analýzy

Mechanismem je rozdělení datového souboru na jednotné prvky, které již nejsou dále dělitelné. Nedochozí zde tedy ke tvorbě hierarchické struktury. Pokud je každá dvojice prvků odlišná, hovoříme zde o tvrdém prahování, pokud má některé prvky společné, potom o prahování měkkém. Dělení začíná počátečním rozkladem, který je iterativně vylepšován, dokud nedojde k optimalizaci. Počáteční shluky mohou být buď náhodně zvolené, nebo mohou být tvořeny výstupem z předběžného procesu shlukování, např. hierarchického.

Nehierarchické metody mají výhodu v aplikacích, které obsahují velké množství dat a použití hierarchických metod by zde bylo výpočetně velmi náročné.

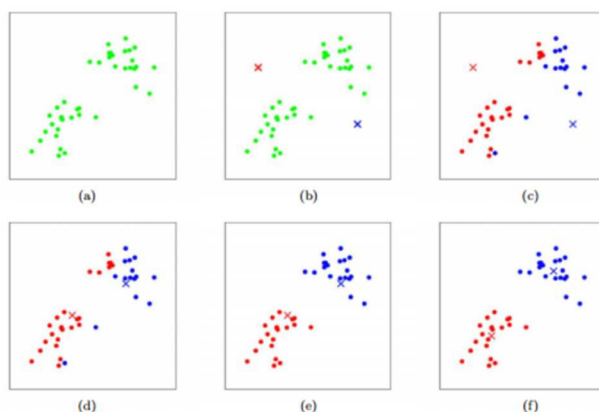
Důležitým parametrem je zde však zvolení počátečního počtu shluků, což bývá stěžejním problémem při výstupní kvalitě shlukování. Stanovení počátečních shluků je tedy nutné často optimalizovat ještě před spuštěním samotného algoritmu, neboť odhadnutí správného počtu je často pouhým okem nerealizovatelné, viz Obr. 15, kde lze ze sady neoznačených prvků možno zvolit několik variant počtu shluků, které nemusí být vždy adekvátním řešením daného problému [12, 13, 48].



Obr. 15: Ukázka jednotlivých variací pro rozdělení prvků do shluků [29]

2.5.1 Metoda k-means

Shlukování na základě metody k-means je v současnosti jedno z nejvíce užívaných v oblasti statistiky, informatiky a zpracování obrazu. Metoda je založena na přiřazení n datových prvků do k shluků, a to tak, že prvky s největší mírou podobnosti náležejí ke stejnému shluku. Jako metoda pro výpočet podobnosti mezi jednotlivými prvky shluků se nejčastěji používá Euklidovská metrika. K-means řadíme do skupiny metod s tvrdým přístupem, což znamená, že daný prvek můžeme ke shluku přiřadit pouze na základě binární úrovně 0 a 1.



Obr. 16: Jednotlivé kroky metody k-means při přerozdělování prvků do shluků [44]

Metoda pracuje v několika iteracích, kde s každou iterací přiřazuje jednotlivé prvky ke svým shlukům dle nejmenší vzdálenosti bodu od shluku, viz vzorec (2.4). Následně metoda překalkuluje těžiště jednotlivých shluků průměrem všech jejich jednotlivých prvků, které shluku náležejí. Tyto kroky jsou opakovány, dokud nedojde ke konvergenci, viz Obr. 16.

Metoda má výhodu v aplikacích, kde je obsaženo větší množství dat a použití triviálních metod by zde bylo výpočetně náročné. Existuje zde však značná nevýhoda a tou je nemožnost optimalizace počátečního rozložení těžišť, které zapříčiní, že výstupní data budou po každé s odlišným výsledkem [12, 13, 18].

Algoritmus metody k-means:

1. počáteční nastavení počtu shluků,
2. náhodné přerozdělení prvků ke shlukům,
3. přepočítání těžiště každého shluku,
4. výpočet vzdáleností prvků od těžišť shluků,
5. přiřazení prvků k nejbližšímu z těžišť,
6. opakování, dokud nedojde ke konvergenci.

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2, \quad (2.4)$$

kde:

J je objektivní funkce;

k je počet shluků;


n je počet objektů;

x je objekt;

c je těžiště shluku.

2.5.2 Metoda fuzzy c-means

Jedná se o modifikaci metody k-means založenou na fuzzy logice, někdy také nazývána FCM či fuzzy k-means. Výhodou oproti k-means je, že přiřadí každý prvek k danému shluku s určitou mírou členství. Nehovoříme zde tedy pouze o binárním rozhodování jako u k-means, ale prvky zde mohou být přiřazeny ke shluku s určitou mírou příslušnosti, ta se pohybuje od 0 do 1, viz Obr. 17 a 18. Tento koncept je vhodnější pro skutečné aplikace, kde mezi shluky v datové sadě dochází k určitému překrývání. Obecně platí, že FCM funguje lépe než k-means a je méně ovlivněná přítomností nejistoty v datech. Stejně však jako k-means je náchylná na odlehlé hodnoty v souboru dat a zároveň také vyžaduje, aby uživatel určil počet počátečních shluků [16, 19, 30].



Obr. 17: Vlevo binární tvrdé rozhodování, vpravo měkké rozhodování na základě fuzzy logiky [30]

1. zvolení počtu shluků,
2. náhodné přiřazení míry příslušnosti každému z objektů,
3. výpočet těžiště shluku,
4. výpočet míry příslušnosti každého objektu k danému shluku,
5. tyto dva předchozí body jsou opakovány, dokud není dosaženo optimálního řešení.

Krok 1:

$$J_m = \sum_{j=1}^D \sum_{i=1}^N \mu_{ij}^m \|x_i^{(j)} - c_j\|^2, \quad (2.5)$$

Krok 2, 3:

$$c_j = \frac{\sum_{i=1}^D \mu_{ij}^m x_i}{\sum_{i=1}^D \mu_{ij}^m}, \quad (2.6)$$

Krok 4:

$$\mu_{ij} = \frac{1}{\sum_{k=1}^N \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}, \quad (2.7)$$

kde:

D je počet objektů;


N je počet shluků;

m je objekt patřící současně do více než jednoho shluku zároveň;

x je každý i -tý objekt;

c je těžiště j -shluků;

μ je míra příslušnosti objektu ke shluku.



Obr. 18: Rozložení shluků dle metody fuzzy c-means, kde každému prvku náleží určitá míra příslušnosti ke svému shluku [16]

2.5.3 Metoda KHM (k-harmonic means)

K-harmonický průměr, z angličtiny také k-harmonic means, je modifikací klasické metody k-means. V metodě se používá objektivní funkce, a to pro každý datový bod se vzdáleností ke všem centrům. Harmonický průměr je citlivý na skutečnost, pokud existují dvě nebo více center blízko datového bodu. Algoritmus přirozeně posune jedno nebo více z těchto center do oblastí, kde jsou

datové body, které nemají žádný blízký střed. Tím se vytvoří nižší hodnota pro objektivní funkci. V každé iteraci standardní k-means a FCM dává objektivní funkci stejnou váhu všem datovým bodům.

KHM se vymezuje tím, že přiřazuje dynamické váhy každému datovému bodu na základě harmonického průměru. Harmonický průměr přiřadí velkou váhu datovému bodu, který není v blízkosti žádného centra a malou váhu datovému bodu, který je blízký jednomu nebo více středům, viz vzorec (2.8). Tento princip je důležitý, protože se chceme vyhnout vytváření hustě nashromážděných oblastí několika center dohromady. Zvýšením váhy středů, které nejsou v blízkosti žádného středu, může algoritmus přilákat centra od těchto hustých oblastí, aniž by se zvýšila váha datových bodů, které jsou ve více hustých oblastech. Tento princip je méně citlivý při inicializaci než k-means a FCM, neboť pro příklad u metody k-means mají centra tendenci být uvězněny v husté oblasti, což vede ke špatným výsledkům shlukování [31].

$$KHM(X, C) = \sum_{i=1}^n \frac{k}{\sum_{j=1}^k \frac{1}{\|x_i - c_j\|^p}}, \quad (2.8)$$


kde:

k je počet shluků;
n je počet objekt;
x je objekt;
c je těžiště shluku.

2.5.4 Metoda PAM (Partitioning Around Medoids)

V počátku dochází k určení reprezentativního bodu pro každý shluk datového souboru. Tento reprezentativní bod je umístěn co nejvíce ve středu shluku a nazýváme ho medoid. Následně se vypočte průměrná odlišnost všech dříve nevybraných bodů vůči zvoleným medoidům. Prvotní medoid disponuje minimálním součtem vzdáleností od ostatních bodů. Poté jsou body přiřazeny k medoidům, ke kterým vykazují nejvyšší pravděpodobnost náležitosti.

Metoda pracuje iterativně, kde s každým přepočtem dochází k výběru kvalitnějších medoidů. Metoda je velmi hojně využívána u úloh, kde se vyskytují odlehle hodnoty či šum v datech, neboť PAM je v těchto ohledech velice odolná v porovnání například s metodou k-means či FCM, kde by docházelo ke zkreslení výsledku. Ukázka reprezentativních medoidů je vyobrazena na Obr. 19 [32, 33].



Obr. 19: Rozdělení shluků pro metodu PAM [vlastní]

2.5.5 Metoda CLARA (Clustering Large Applications)

Algoritmus CLARA je rozšířením metody PAM pro velké datové soubory, kde má v úmyslu zkrátit dobu výpočtu v případě velké datové sady. Metoda nebere v úvahu datový soubor jako celek, ale místo toho používá randomizovaný vzorek datového souboru, ze kterého jsou vyčleněny nejlepší medoidy. Koncept spočívá v tom, že pokud je vzorek vybrán poměrně náhodným způsobem, pak jeho medoid bude správně představovat celou sadu dat. Nejdůležitější výhodou CLARA je to, že funguje na více vzorcích a poskytuje nejlepší shluky z dané sady vzorků [32, 33].

2.6 Metody pro optimalizaci počtu shluků

Určení optimálního počtu shluků v datové sadě je zásadním problémem u metod, které vyžadují, aby uživatel určil počet shluků, které mají být generovány. Bohužel na tuto otázku neexistuje definitivní odpověď. Optimální počet shluků je do jisté míry subjektivní a závisí na metodě použité k měření podobnosti a na parametrech použitých k následnému rozdělení datové sady. Jednoduché a populární řešení spočívá ve vytvoření dendrogramu, pomocí hierarchického shlukování, aby se zjistilo, zda se jasně ukáže konkrétní počet. Ne však vždy je tento princip úspěšný, proto byly navrženy metody, které počet shluků dokážou stanovit s vyšší přesností.

Jedním z objektivních parametrů hodnocení stanoveného počtu shluků je Dunn index, ten dává výsledný poměr minimální vzdálenosti mezi shluky a maximální vzdálenosti uvnitř shluku, viz vzorec (2.9). Spolu se vzdáleností mezi těžišti a prvky zohledňuje také vzdálenost mezi dvěma shluky. Tato vzdálenost mezi těžišti dvou různých shluků je známá jako mezishluková vzdálenost. Aby se maximalizovala hodnota Dunnova indexu, měl by být číselník maximální. Vzdálenost mezi nejbližšími shluky by tedy měla být větší, což nakonec zajistí, že shluky budou od sebe daleko [24, 34].

$$Dunn\ index = \frac{\min(\text{externí vzdálenost shluků})}{\max(\text{interní vzdálenost shluků})} \quad (2.9)$$

2.6.1 Metoda Elbow

Pravděpodobně nejznámější metoda „zlomu lokte“, ve které je vypočítán a graficky znázorněn součet čtverců u každého počtu shluků. Uživatel následně hledá změnu sklonu ze strmého na mělký, aby určil optimální počet shluků. Myšlenka spočívá v tom, že první shluky vykazují mnoho variací, protože se data v počátku skládají z mnoha skupin, takže tyto prvotní shluky jsou nezbytné, ale jakmile počet shluků překročí skutečný počet skupin dat, nastane prudké zkreslení výsledku, protože dochází pouze k rozdělování již vytvořených shluků. Za předpokladu, že problém nastane, bude v grafu vyobrazen tzv. ostrý loket, což znamená, že křivka bude rychle klesající až k ideálnímu počtu shluků a poté bude klesání zpomaleno, viz Obr. 20. Tato metoda je nepřesná, ale přesto v mnoha případech potenciálně užitečná [24].


2.6.2 Metoda Siluety

Silueta vybraného objektu měří, jak dobře je daný objekt shlukován v přiděleném shluku. Výsledná hodnota této metody je dána intervalem v rozmezí [-1,1], kdy pokud inklinuje k 1, tak je

objekt dobře shlukován, pokud $k > 0$, tak je na hranici daného shluku a pokud je menší než 0, tak je objekt pravděpodobně shlukován ve špatném shluku [24].

2.6.3 Metoda statistické mezery

Nevýhodou metody Elbow a průměrných siluet je, že měří pouze globální shlukovací charakteristiku. Sofistikovanější je použití metody statistické mezery, která poskytuje postup k formalizaci heuristiky loktu a siluety za účelem odhadu optimálního počtu shluků. Statistická metoda mezery byla poprvé publikována 2001 (R. Tibshirani, G. Walther, a T. Hastie, Stanford University). Tento přístup lze použít na jakoukoliv metodu shlukování. Statistická metoda mezery porovnává součet v rámci variace uvnitř shluku pro různé hodnoty k s jejich očekávanými hodnotami při nulové referenční distribuci dat. Odhad optimálních shluků bude hodnota, která maximalizuje statistiku mezery. To znamená, že shlukovací struktura je daleko od náhodného rovnoměrného rozdělení bodů [24].



Obr. 20: Grafické znázornění metod pro optimalizaci počtu shluků [24]


3 Rešerše segmentačních technik využívající shlukové analýzy

3.1 Vyhodnocení k-means shlukování zaměřeného na medicínské obrazy

Originální název: MOFTAH, Hossam M., Walaa H. ELMASRY, Nashwa EL-BENDARY, Aboul Ella HASSANIEN a Kazumi NAKAMATSU. Evaluating the effects of K-means clustering approach on medical images. *12th International Conference on Intelligent Systems Design and Applications (ISDA)*, 2012, s. 455-459.

Cílem tohoto článku je vyhodnocení výkonu shlukovacího algoritmu k-means. K dosažení srovnatelného hodnocení byly použity různé lékařské snímky CT a MRI. Lékařské snímky použité v tomto článku pro experimenty byly shromážděny z CT snímků jater s obecnou vnitřní variací tkáně a MRI snímků prsu. Velikost všech testovaných obrázků byla 431 x 339 pixelů, viz Obr. 21. Získané experimentální výsledky ukazují, že celková přesnost segmentace nabízená přístupem k-means je vyšší ve srovnání s přesností metody normalizované segmentace řezu.


Pro vyhodnocení snímků jednotlivých segmentací je v tomto článku použito několik měřítek algoritmů založených především na struktuře a tvaru oblastí zájmů obrazových dat. Míra přesnosti je definována u více typů objektů. Míry založené na texturách obrazu, u nichž se ukázalo, že jsou výpočetně efektivní, zahrnují průměr, který je měřítkem jasu, entropii která je mírou náhodnosti a standardní odchylky (STD), která je mírou kontrastu.



Obr. 21: Srovnání testovaných metod na MRI obrazech nádoru prsu

Obr. 22 znázorňuje komparativní analýzu, která zdůrazňuje přesnost segmentace algoritmů k-means a normalizovaných řezů pro analyzované vzorky jaterního CT a MRI prsu. Ukazuje se, že shlukování za pomoci metody k-means dosáhlo vyšší přesnosti ve srovnání s algoritmem normalizace řezů, a to s ohledem na stejné vzorky. Pro vyhodnocení přesnosti segmentace byl test zaměřen na oblast zájmu, což je část, která obsahuje nádor. Jak je znázorněno na Obr. 21, u vzorků jaterních CT LS1, LS2 a LS3 je průměr přesnosti segmentované části pomocí k-means 88,68 % (70,71 % pro LS1, 99,9 % pro LS2 a 95,97 % pro LS3), zatímco průměr přesnosti segmentovaného dílu používajícího normalizované řezy je 75,39 % (45,43 % pro LS1, 86,71 % pro LS2 a 94,04 % pro LS3).

Podobně u vzorků MR1 prsu, BS1 a BS2 je průměr přesnosti segmentované části (ROI) s použitím k-means 78,40 % (77,80 % pro BS1 a 78,99 % pro BS2), zatímco průměr přesnosti segmentované části pomocí normalizovaných řezů je 75,51 % (75,12 % pro BS1 a 75,89 % pro BS2).




Obr. 22: Výsledné srovnání jednotlivých snímků jater a prsu v kontextu testovaných metod

Všechny výsledky byly porovnány pomocí analýzy, která zdůrazňuje přesnost a robustnost obou segmentačních algoritmů aplikovaných na medicínské snímky. Získané experimentální výsledky ukazují, že celková přesnost k-means je mnohem vyšší ve srovnání se známým normalizovaným přístupem segmentace řezů.

3.2 Efektivní metody segmentace pro detekci nádoru v MRI obrazech

Originální název: SINHA, Kailash a G. R. SINHA. Efficient segmentation methods for tumor detection in MRI images. *IEEE Students' Conference on Electrical, Electronics and Computer Science*, 2014, 2014, s. 1-6.

MRI funguje jako pomocný nástroj pro lékaře během diagnostiky a léčby pacienta při zobrazení měkkých tkání. Článek představuje komparativní analýzu tří metod segmentace implementovaných pro nádorovou detekci. Metody zahrnují k-means shlukování s algoritmem Watershed, optimalizovanou metodu k-means genetickým algoritmem a optimalizovanou metodu FCM genetickým algoritmem. Na konci segmentace je nádor extrahován z MRI obrazu a je dodatečně určena jeho přesná poloha a tvar.



Obr. 23: MRI obrazy mozku určené pro následnou segmentaci

Čas a hledání oblasti nádoru byly hodnoceny jako parametry pro srovnání jednotlivých metod. V tomto článku bylo použito 50 MRI snímků mozku, které byly zpracovány jako obrazy v reálném čase za pomoci radiologů z diagnostického centra. Některé MRI obrazy jsou zobrazeny na Obr. 23. Tyto obrazy jsou vystaveny různým metodám segmentace pro následnou detekci nádorů přítomných ve snímcích. Testování je realizováno pomocí procesu dvou fází. První fáze používá k-means nebo FCM shlukování, kde výsledky primární segmentace jsou dále zpracovávány v druhé fázi procesu, kde je použit jako algoritmus segmentace Watershed či genetické algoritmy pro zlepšení výsledku primární segmentace.

Výsledky algoritmu Watershed aplikovaného na stejné testovací obrazy jsou uvedeny na Obr. 23. Srovnání výsledků z hlediska jednotlivých oblastí je uvedeno v Tabulce 1 vlevo.

Tabulka 1: Vlevo tabulka srovnávající metody k-means a optimalizovaný k-means, uprostřed srovnávající metody FCM a optimalizovaný FCM a vpravo metody optimalizovaný k-means a FCM

S. No.	Test images	Tumor area using traditional k-means clustering (pixel value)	Tumor area using optimized k-means clustering (pixel value)	S. No.	MRI test images	Traditional c-means clustering (Tumor area in pixels)	Optimized c-means clustering (Tumor Area in pixels)	S. No.	Test images	Tumor area using optimized k-means clustering (pixel)	Tumor area using optimized c-means clustering (pixel)
1	MRI _a	698	823	1	MRI _a	642	902	1	MRI _a	823	902
2	MRI _b	597	798	2	MRI _b	623	856	2	MRI _b	798	856
3	MRI _c	624	729	3	MRI _c	598	829	3	MRI _c	729	829
4	MRI _d	729	913	4	MRI _d	689	1013	4	MRI _d	913	1013

Výsledky experimentu naznačují, že genetický algoritmus spolu s FCM nejen eliminuje problém nekvalitní segmentace, ale také poskytuje rychlé a efektivní shlukovací výsledky. Článek porovnává tradiční metodu shlukování k-means s algoritmem Watershed. Úroveň segmentace v optimalizované metodě je lepší než u tradičního shlukovacího algoritmu. Zároveň optimalizovaná metoda FCM prokázala lepší výsledky než implementace klasické FCM, viz Tabulka 1 uprostřed.

Tabulka 1 vpravo uvádí srovnání mezi optimalizovanými metodami k-means a optimalizovanými shlukovacími metodami FCM. Je vidět, že FCM funguje lépe než optimalizovaná metoda k-means, protože segmentovaná oblast a úroveň zájmové oblasti je zde lépe detekována.

Další srovnání bylo provedeno také z hlediska výpočetní náročnosti pro optimalizované metody k-means a FCM uvedené v Tabulce 2. Potřebná doba segmentace je kratší u metody shlukování optimalizovanou FCM ve srovnání s metodou k-means. Metodu shlukování FCM lze tedy považovat za efektivnější než optimalizovaný algoritmus k-means.

Závěrem článku tedy je, že za pomoci optimalizace jednotlivých shlukovacích algoritmů k-means a FCM jsme schopni zvýšit jejich robustnost, tím pádem zajistit lepší segmentaci a následnou diagnostiku pacienta.

Tabulka 2: Vyhledávací čas pro optimalizovanou metodu k-means a FCM

S. No.	Test images	Search time for optimized k-means clustering with number of iterations (sec.)	Search time for optimized c-means method with number of iterations (in sec.)
1	MRI _a	66.879(104)	3.998(104)
2	MRI _b	64.568(102)	3.998(102)
3	MRI _c	70.435(105)	4.125(104)
4	MRI _d	73.249(107)	5.987(103)

3.3 Obrazová segmentace využívající hrubý fuzzy k-medoid algoritmus

Originální název: HALDER, Amiya, Avijit DASGUPTA a Susmita GHOSH. Image segmentation using rough-fuzzy K-medoid algorithm. *International Conference on Communications, Devices and Intelligent Systems*, 2012, s. 105-108.

V tomto článku je navržena segmentace pro barevný obraz na základě metody hrubý fuzzy k-medoid. Hlavním cílem tohoto algoritmu je poskytnout efektivní metodu využívající informaci o barvě a vztahu jednotlivých sousedících pixelů. V článku je navržena modifikace algoritmu k-medoid, který má dvě části. V první části jsou optimalizována počáteční centra shluků hrubou teorií množin a ve druhé části se optimální shluk centra použije k provedení algoritmu k-medoid. Testování nevyžaduje žádné předchozí informace o datové sadě. Výsledky jsou porovnány s pěti dalšími segmentačními algoritmy, viz Obr. 25.

Teorie hrubé množiny je matematický nástroj pro analýzu neurčitosti a nejistoty při rozhodování. Hlavní výhoda teorie hrubých množin je to, že se nespolehá na doplňkové informace z datového souboru, ale naopak analyzuje a zjišťuje závislé vztahy mezi nimi.

Základní strategie algoritmu k-medoid je najít zcela libovolně centra shluků ze sady datových bodů. Zbývající objekty jsou pak seskupeny s medoidem, kterému jsou nejvíce podobné. Metoda k-medoid používá jako referenci reprezentativní objekty bodů namísto průměrné hodnoty objektů v každém shluku. Jako vstupní parametr algoritmus bere v úvahu počet shluků v sadě datových bodů.

Typický algoritmus k-medoid je popsán následujícími kroky:


1. inicializace náhodným výběrem k datových bodů jako medoidy z n datových bodů,
2. přiřazení datových bodů k nejbližšímu medoidu,
3. pro každý medoid je následně každý ne-medoidní datový bod o zaměněno m a o a je vypočítána celková konfigurace,
4. výběr konfigurace s nejnižším výsledkem,
5. opakování kroků 2 až 4, dokud nedojde ke změně v medoid.



Obr. 24: Srovnání výsledků segmentačních metod na obrázku Lena

Algoritmus se pokouší určit k shluků pro n objektů. Po počátečním náhodném výběru k -medoidů se algoritmus opakovaně pokouší zajistit lepší polohu medoidu. Následně se vyhodnocuje účinnost navrhovaného algoritmu prováděním experimentů na čtyřech standardních obrazech, viz Obr. 24. Výsledky jsou porovnány s pěti nejmodernějšími algoritmy segmentace obrazu, a to k -means, FCM, hrubý k -means, hrubý FCM (označované jako Rough FCM) a k -medoid.

Výsledky jsou hodnoceny indexem platnosti (validity index). Jako výstup lze na grafu, viz Obr. 25 vidět, že segmentace pomocí navrhovaného algoritmu, stejně jako dalších pět nejmodernějších technik jasně ukazuje, že navrhovaný a testovaný algoritmus poskytuje lepší index platnosti než ostatní algoritmy.



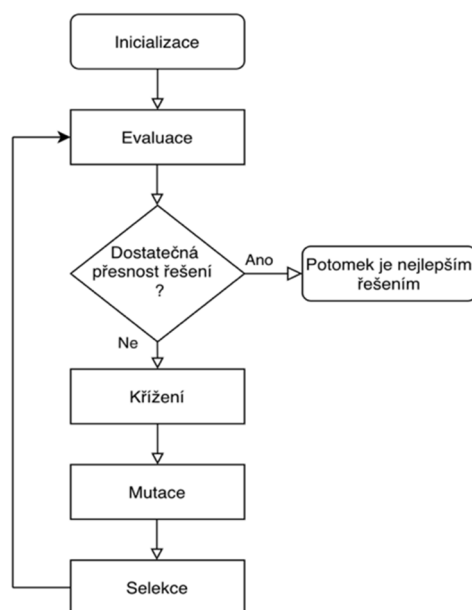
Obr. 25: Index platnosti pro jednotlivé segmentační metody

4 Optimalizační metody na bázi umělé inteligence

Hlavním problémem shlukovacích metod pro segmentaci obrazu je počáteční zvolení těžišť, jak již bylo zmíněno v předchozích kapitolách. Doposud není známá žádná metoda, která by vždy s úspěchem prvotní trežističe inicializovala. Optimalizační metody na bázi evoluce a genetiky jsou inspirovány biologickými jevy – genetické struktury a mechanismy dlouhodobého evolučního vývoje. Na základě těchto informací mohou být za pomoci algoritmů vytvořeny modely optimalizující například právě rozložení prvotních těžišť u metod shlukové analýzy [35, 43].

4.1 Genetické algoritmy

Genetické algoritmy vycházejí z modelu teorie přirozeného vývoje Charlese Darwina. Algoritmy odrážejí celkový proces přirozeného výběru a simulují boj o přežití jednotlivců. Jedinci s nevhodnějšími vlastnostmi jsou vybráni pro následující reprodukci, aby se vytvořilo kvalitnější potomstvo další generace. Spadají do skupiny evolučních algoritmů, které na rozdíl od tradičních algoritmů disponují svou dynamičností a mohou se tudíž vyvíjet v čas, viz Obr. 26 [36].



Obr. 26: Vývojový diagram genetického algoritmu [vlastní]

4.1.1 Inicializace

Proces je v počátku dán náhodnou skupinou jednotlivců, kterou nazýváme populace. Každý jedinec je možným výsledkem problému, který chceme vyřešit. Jednotlivci jsou charakterizováni sadou parametrů nazývaných se geny. Spojením jednotlivých genů do řetězce vzniká základní prvek biologické populace nazývaný se chromozom [35, 37].

4.1.2 Evaluace


Každý jedinec je kandidátním řešením daného problému a jeho kvalita je kvantitativně vyjádřitelná pomocí hodnotící funkce (fitness funkce). Úkolem genetického algoritmu je vyšlechtit takového jedince (řešení), pro kterého bude tato hodnotící funkce vycházet nejlépe. V okamžiku, kdy se vytvoří nebo inicializuje nová populace, provede se vyhodnocení fitness funkce. Výsledkem je pro nás dle typu řešeného problému maximalizace či minimalizace funkce, která předurčuje kvalitativně lepší řešení problému [35, 37].

4.1.3 Selektce

Dalším krokem je výběr nejvhodnějších jedinců z populace, kteří se účastní rekombinace a následně předají své geny další populaci. Dva páry jedinců (rodičů) jsou vybrány dle jejich hodnoty fitness funkce. Jedinci s vyšší kondicí mají větší pravděpodobnost k vybrání. Zároveň ale musíme zaručit, že se rekombinace může zúčastnit i nejhorší z jedinců v populaci. To je realizováno přiřazením pravděpodobnostní funkce přežití každému z chromozomů, která závisí na použití selekční metody výpočtu.

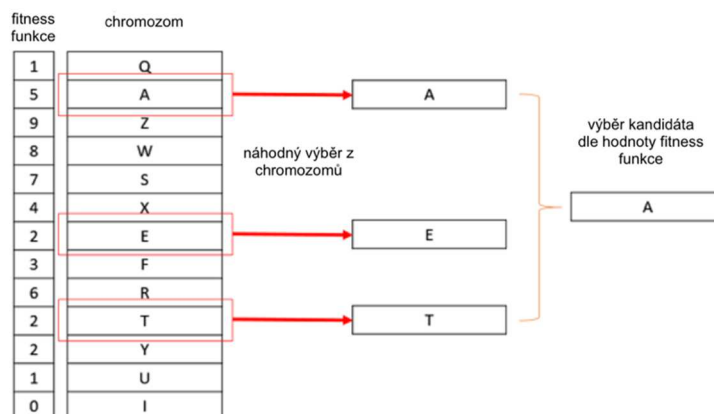
První z nich je Ruletová selektce, tato metoda vrací každého jedince s pravděpodobností odpovídající jeho poměrné kvalitě. Přežití jednotlivého jedince je přirovnáváno k točení ruletovým kolem, kde náhodným pokusem je jedinec, na kterého padne kulička. Přičemž platí podmínka, že jedinec s vyšší kvalitou zabírá více políček rulety, viz Obr. 27.

Další z metod výběrů je Pořadová selektce, zde dochází k vrácení jedince s pravděpodobností odpovídající jeho pořadí v posloupnosti podle kvality chromozomů [37].



Obr. 27: Ruletová selektce [37]

Další z metod je Turnajová selektce. Metoda vybírá náhodně množinu M z n jedinců z původní populace o velikosti x , viz Obr. 28. Vybraná množina realizuje skupinu jedinců konající souboj v turnaji. Do nové populace $M + 1$ se přenesou vítězové (jedinec či více jedinců z vybrané množiny). Metoda umožňuje také nastavení selekčního tlaku. Největší selekční tlak je $x=n$, což odpovídá výběru nejlepších jedinců. Opačná možnost $x=1$ vypovídá o zcela náhodném výběru [37].



Obr. 28: Turnajová selekce [37]

4.1.4 Křížení

Křížení vytváří novou generaci potomstva s nesením genu od obou svých rodičů. Ze dvou chromozomů rodičů se vybere náhodný bod v chromozomu, kde dojde k rozdělení a následnému křížení jednotlivých genů, viz Obr. 29. Novým řešením bude v tomto případě kombinace náhodných nebo cílených křížení, která jsou poté evaluována a ohodnocena. Křížení je důležitým prvkem genetického algoritmu, neboť bez něj by byl potomek stejný jako jeho rodič [35, 37].

4.1.5 Mutace

Další variantou je operátor mutace. Každému z potomků jsou vybrány některé geny, kterým je pozměněna genetická informace. Pokud by šlo kupříkladu o binární kódování, výsledkem bude převrácení binární hodnoty jednoho nebo více genů, viz Obr. 29. Pokud máme více hodnot nepocházejících z binárního rozložení a jsou odlišné, je nutné vybrání a dosazení náhodné hodnoty do původního souboru [35, 37].




Obr. 29: Znáznornění křížení a mutace na binárních hodnotách [vlastní]

4.2 Evoluční algoritmy

Evoluční výzkum algoritmů a aplikací začal před více než 50 lety. Evoluční algoritmy (EA) jsou obecně známé jako univerzální optimalizační algoritmy, které jsou schopny najít téměř optimální řešení numerických testovacích problémů se skutečnou hodnotou, u nichž přesné a analytické metody nepřinášejí optimální řešení v rozumné době výpočtu. Typickým rysem těchto algoritmů je prohledávání skupiny dat na základě populací. Uplatnění se nalézá především v oblastech s vysokým počtem vstupních dat s mnoha lokálními optimy [39].

4.2.1 PSO

Optimalizace roje částic, dále jen PSO, z anglického Particle Swarm Optimization, je evoluční algoritmus vytvořen Eberhartem a Kennedym v roce 1995. Inspiraci nalézá v biologických procesech, jako je chování hejn ryb a ptáků. Principem je vyslání populace částic do prostoru, kde každá z nich prolétává určitou rychlostí. V jednotlivých krocích je pro každou z částic určena individuální rychlost, a to na základě pozice nejlepší částice a také částic nacházejících se v jejím okolí, viz Obr. 30 [41].



Obr. 30: Aktualizace jednotlivých částic zobrazená vektorem [41]


Rychlost částic je navíc čas od času dynamicky upravována podle vlastních zkušeností a informací sdílených mezi ostatními částicemi v jejich sousedství. K vyhodnocení aktuální polohy všech částic je použito kritérium specifické pro daný problém, kterému se říká fitness funkce a navádí roj k letu na nejlepší místo. Pokud jsou poloha a rychlost i -té částice v i -té iteraci reprezentovány $x_i(t)$ a $v_i(t)$, jsou aktualizovány následovně [42, 43]:

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (4.1)$$

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (pbest_i(t) - x_i(t)) + c_2 \cdot r_2 \cdot (gbest(t) - x_i(t)), \quad (4.2)$$

kde $pbest_i(t)$ je nejlepší předchozí pozice i částice neboli hodnota fitness funkce, $gbest(t)$ je globálně nejlepší pozice mezi všemi částicemi. c_1 a c_2 jsou dva pozitivní faktory učení, r_1 a r_2 jsou rovnoměrně rozložená náhodná čísla nabývající intervalu $< 0,1 >$ a ω je koeficient setrvačné hmotnosti používaný k řízení dopadu předchozí rychlosti částice mezi 0 a 1. Část rovnice $v_i(t+1)$ nazýváme setrvačností, neboť představuje pohyb částice v původním směru, tento parametr může být násoben určitou váhou [43].

Jedním z parametrů pro správnou funkci algoritmu je výběr topologie, kterou definujeme jako komunikační strukturu celého roje. Na základě různých topologických struktur, viz Obr. 31, jsme schopni omezit komunikaci mezi jednotlivými částicemi za účelem zabránění uvěznění roje v lokálním minimu. Struktura topologie může být i dynamická, a to v závislosti na řešené úloze, standardně se však dělí na lokální a globální [43].




Obr. 31: Nejčastěji používané topologie PSO: a) kruhová, b) globální, c) Von-Neumanova [40]

Algoritmus vycházející z principu umělé inteligence vykazuje spolehlivost a výkon rychlé konvergence u řady obtížných optimalizačních problémů i v případech, kdy ve vstupních datech je vysoká nelinearita či rozdílná velikost.

Výhodou oproti genetickým algoritmům je jednodušší implementace s nastavením menšího počtu vstupních parametrů simulace. Vzhledem k zapamatování předchozí hodnoty každé částice a hodnoty okolních částic je efektivita vyšší než u genetických algoritmů, zároveň je udržitelná rozmanitost v populaci díky využití informace od nejlepších částic ke svému zlepšení, namísto u genetických algoritmů, kde nejslabší optimalizace řešení zanikají [43].

4.2.2 ABC

Algoritmus umělé včelí kolonie (ABC) vyvinul Karaboga v roce 2005. Jedná se o optimalizační algoritmus inspirovaný inteligentním chováním včelího roje. Principem je hledání potravy za pomoci různých druhů včel, které mají na starosti odlišné úkoly, viz Obr. 32. Základem jsou tři druhy včel zaměstnané jako dělnice, vyčkávací včely a průzkumnice. Jejich úkolem je zlepšení zdroje potravy. V počáteční fázi včely směřují do prohledávaného prostoru a jsou zároveň určeny náhodným výběrem [38].



Obr. 32: Znáznornění funkce algoritmu ABC na včelím roji [38]

Hlavním cílem je maximalizovat množství potravy v úlu. Pro každý zdroj potravy existuje pouze jedna dělnice a jejich celkový počet se rovná počtu zdrojů potravy. Dělnice určují zdroj potravy pomocí

prohledávání okolí v rámci původního zdroje potravy uloženého v paměti. Následně dělnice sdílejí své informace s vyčkávacími včelami v úlu a ty se poté snaží vylepšit dosavadní řešení dané dělnice. Pokud lepší řešení není nalezeno, zůstává dělnice na svém místě. Pokud však nedojde ke zlepšení řešení dělnic po několika opakováních, tak opouští své místo a stane se průzkumníci, která si vybírá náhodný bod v prostoru a převtěljuje se znovu do dělnice, ovšem tentokrát na jiném místě, kde pokračuje ve svém úkolu.

Vstupní nastavení algoritmu se skládá z velikosti roje a poměru mezi počtem dělnic a vyčkávacích včel. Dalším parametrem nastavení je také počet iterací, kdy dělnice zanechává své řešení díky neschopnosti ho zlepšit. Kalkulace nové pozice vyčkávací včely je dána následujícím vzorcem [38, 39, 43].

$$x_{ij}(t + 1) = \theta_{ij}(t) + \emptyset(\theta_{ij}(t) - \theta_{kj}(t)), \quad (4.3)$$

kde:

x_i je pozice vyčkávací včely;

t je počet iterací;

θ_{kj} náhodně vybraná dělnice;

j dimenze řešení;

\emptyset náhodná proměnná v intervalu $[-1,1]$.

Se zvyšujícím se množstvím zdroje potravy se úměrně zvyšuje pravděpodobnost preferovaného zdroje vyčkávacích včel, a to dle následujícího vzorce (4.4).

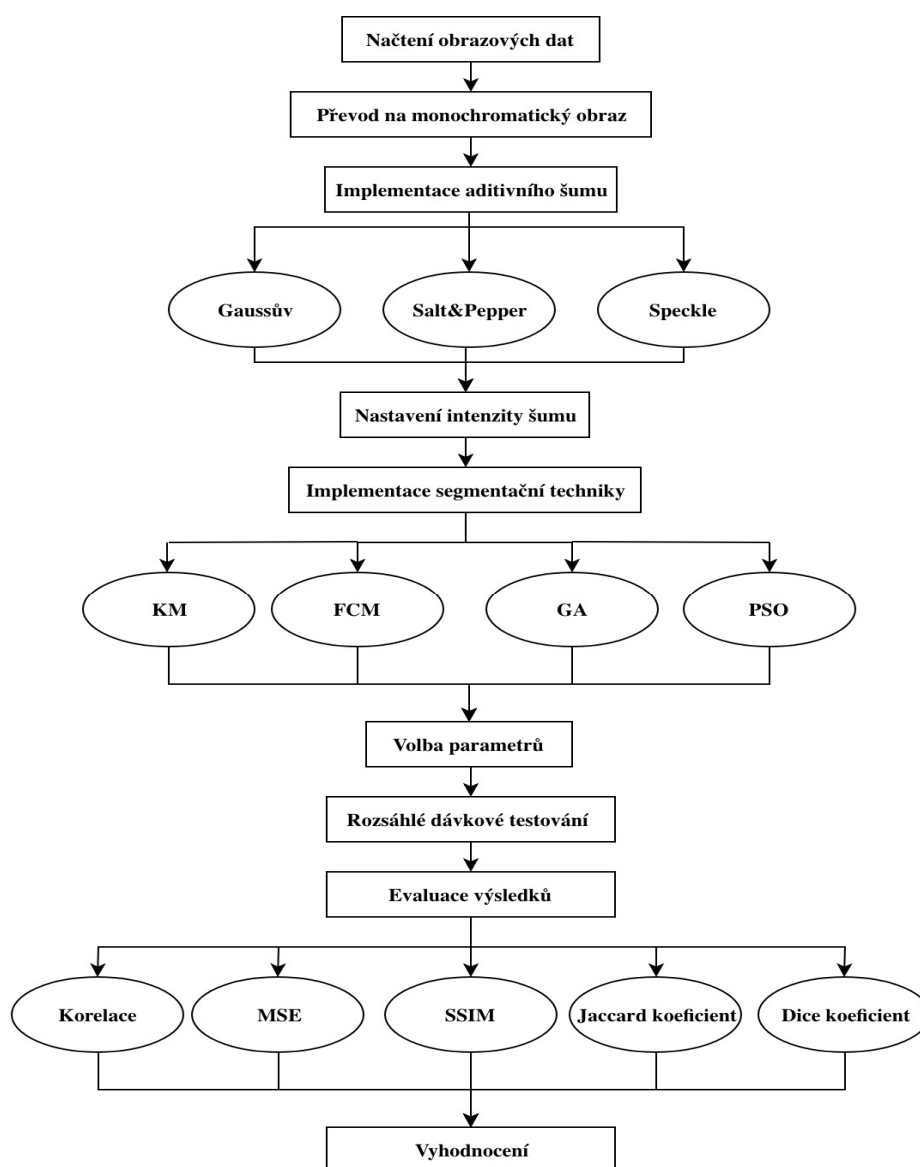
Hodnota S vyjadřuje velikost populace zaměstnaných včel, $F(\theta_i)$ je hodnota fitness funkce, θ_i je pozice i -té zaměstnané včely. Celková pravděpodobnost vybrání i -té včely je dána na základě hodnoty P_i a je tím vyšší, čím je lepší kvalita řešení. V závěrečné fázi dochází k výběru výsledné hodnoty P_i , která dosahuje maximální hodnoty [39, 43].

$$P_i = \frac{F(\theta_i)}{\sum_{k=1}^S F(\theta_k)} \quad (4.4)$$

5 Experimentální část

Záměrem této části je globální testování algoritmů pracujících na principu umělé inteligence ve srovnání s klasickým konvenčním algoritmem k-means. Testování je provedeno v prostředí MATLABu a předchází mu několik níže popsanych fází, viz Obr. 33, kde postupně dochází k načtení obrazových databází, následně jsou snímky databáze převedeny do monochromatického formátu, další fází je zašumění jednotlivých snímků parazitními šумы. Posléze jsou již implementovány jednotlivé segmentační algoritmy.

Výstupem práce jsou grafická srovnání postavená na níže zmíněných evaluačních metrikách, kde jsme schopni za jejich pomoci přesně stanovit míru úspěšnosti segmentačního algoritmu a určit jeho robustnost v závislosti na variabilních podmínkách, za kterých byl daný obraz pořízen.



Obr. 33: Diagram reprezentující princip celkového testování [vlastní]

5.1 Načtení obrazové databáze

Pro přesné vyhodnocení segmentačních technik v kontextu variabilních šumových podmínek bylo testování realizováno na více medicínských obrazech, které jsou seřazeny v jednotlivých datsetech. Obrazy pocházejí převážně z výpočetní tomografie (dataset 2 a 3) a nukleární magnetické rezonance (dataset 1 a 4). Vzhledem k výpočetní náročnosti bylo pro jednotlivá testování vybráno z každého datasetu 10 snímků, celkově tedy 40 snímků. Všechny snímky jsou ve formátu .jpg, jednotlivé parametry můžeme vidět v Tabulka 3 a na níže zmíněných obrázcích jsou vyobrazeny ukázkové snímky jednotlivých datasetů.

Tabulka 3: Popis obrazové databáze [vlastní]

Databáze	Dataset	Rozlišení (px)	Formát	Počet	Barevný model
1	MRI chrupavky	512x512	.jpg	10	RGB
2	CT cév	1024x1024	.jpg	10	RGB
3	CT jater	630x630	.jpg	10	RGB
4	MRI cév	1067x1046	.jpg	10	RGB



Obr. 34: Ukázka datasetu MRI chrupavky [vlastní]



Obr. 35: Ukázka datasetu CT jater [vlastní]



Obr. 36: Ukázka datasetu CT cév [vlastní]



Obr. 37: Ukázka datasetu MRI cév [vlastní]

Celkové načítání obrazových databází je realizováno pomocí buněčného pole, kde v každé buňce matice je uložen právě jeden snímek. Data je nutné před další úpravou převést na monochromatický obrazový formát, a to za pomoci vestavěné funkce, která je součástí MATLABu, podrobnější popis a výpočet je možné vidět níže, viz. vzorec 5.1.

$$Y = [(0,3 \cdot R) + (0,59 \cdot G) + (0,11 \cdot B)], \quad (5.1)$$

Funkce pracuje na principu vytvoření tří barevných složek RGB modelu na základě metody váženého součtu. Dle vzorce (5.1) je každá ze tří složek vynásobena příslušným koeficientem, který vyjadřuje příspěvek barev RGB do monochromatického modelu kde R , G a B reprezentují jednotlivé barevné složky obrazu (Red, Green a Blue) a Y je výstup ve stupních šedi.

Jednotlivé koeficienty jsou pro červenou barvu 30 %, pro zelenou 59 % a pro modrou 11 %. Pomocí správného výpočtu a procentuálního rozložení jsme schopni docílit optimálního obrazu ve stupnici šedi. Pokud by barva modrá či červená převýšila poměr nad zelenou, dosáhneme jasového útlumu, neboť lidské oko je nejlépe schopno rozeznat barvu zelenou.

5.2 Implementace aditivního šumu

V rámci pořízení obrazu za pomoci radiodiagnostických metod může vzniknout mnoho parazitních jevů, které zhoršují jeho kvalitu. Šum je jedním z hlavních, se kterým se v dnešní době potýkáme. Může vznikat za zhoršených podmínek (teplota, vlhkost, prach) v místě pořízení snímku nebo přímo v elektrických součástkách zařízení.

Pro získání objektivního srovnání testovaných metod je nezbytné degradovat vstupní medicínská data parazitním šumem. Následně jsme schopni definovat robustnost jednotlivých testovaných metod, a to vždy v porovnání nativně segmentovaných snímků se zašuměnými segmentovanými snímky. V rámci komparační analýzy jsme schopni zároveň zjistit náchylnost testovaných metod vůči parazitnímu šumu.

V této práci jsou testovány 3 typy šumu, které jsou synteticky implementovány pomocí přednastavené funkce MATLABu. U každého ze šumu byla nastavena variabilní intenzita s cílem sledování dynamiky šumu v kontextu degradace medicínských obrazů. Rozsah šumu použitý pro robustní testování je viditelný v Tabulka 4 pro počet kroků (1-5). Hodnota (0,35) je volena pro testování extrakce tkání, kde pro lepší diferenciaci metod byl šum uměle navýšen.

Tabulka 4: Nastavení intenzity šumových generátorů [vlastní]

Typ šumu	Gaussův ($\sigma^2=0,01$), (μ)	Salt&pepper (d)	Speckle (σ)
Rozsah šumu	0,013–0,280 (0,350)	0,013–0,280 (0,350)	0,013–0,280 (0,350)
Počet kroků	1–20 (1–5)	1–20 (1–5)	1–20 (1–5)

5.2.1 Gaussův šum

Jedná se o bílý statistický šum, jeho pravděpodobnost výskytu je rovna normální distribuci rozložení. Původ šumu je přisuzován přírodním zdrojům, kupříkladu teplotě okolí. Jeho rozložení je v obraze rovnoměrné a ovlivňuje všechny pixely stejnou intenzitou. Šum je definován parametry střední hodnotou μ a rozptylem σ^2 a je popsán vzorcem (5.2), jednotlivé výstupy snímku jsou vyobrazeny na Obr. 38 [21].


$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (5.2)$$

kde:

x je jasová intenzita šumu,

σ^2 je rozptyl,

μ je střední hodnota.




Obr. 38: Aplikace Gaussova šumu na medicínské snímky. Zleva: nativní snímky; zašuměné snímky $\mu=0,1$, $\sigma^2=0,01$; $\mu=0,2$, $\sigma^2=0,01$ [vlastní]

5.2.2 Šum Salt&pepper

Jedná se o impulsní šum, ve kterém pixel nenese žádnou informaci o původní hodnotě. Degradace obrazu probíhá pouze na několika pixelech v obraze, avšak je velice intenzivní, následně je šum viditelný jako bílé a černé skvrny v obraze podobající se soli a pepři.

U šumu Salt&pepper jsou šumové frekvence vysoké, tudíž dle RGB modelu bude část salt rovna hodnotám RGB okolo 250 a část pepper naopak hodnotám blízcím se 0. Tento šum je možné dobře odfiltrvat pomocí statistických filtrů, nejčastěji mediánovým filtrem. Vstupním parametrem pro nastavení šumu je denzita, jednotlivé výstupy snímků jsou vyobrazeny na Obr. 39 [22].




Obr. 39: Aplikace Salt&pepper šumu na medicínské snímky. Zleva: nativní snímky; zašuměné snímky $d=0,1$; $d=0,2$ [vlastní]

5.2.3 Šum Speckle

Jedná se o běžný šum u všech koherentních zobrazovacích systémů jako jsou lasery, akustické systémy a v medicíně hlavně ultrazvuk. Díky tomuto šumu se snižuje rozlišení a kontrast obrazu, což ovlivní diagnostický přínos zobrazovacích metod.

Důvodem vzniku je interference signálu mající odlišnou fázi při návratu od snímaného cíle. Projevuje se tmavými pixely v obraze s vyšší hodnotou jasů. Šum popisujeme rozptylem σ^2 , jednotlivé výstupy snímku jsou vyobrazeny na Obr. 40 [22].



Obr. 40: Aplikace Speckle šumu na medicínské snímky. Zleva: nativní snímky; zašuměné snímky $\sigma=0,1$; $\sigma=0,2$ [vlastní]

5.3 Implementace segmentačních metod

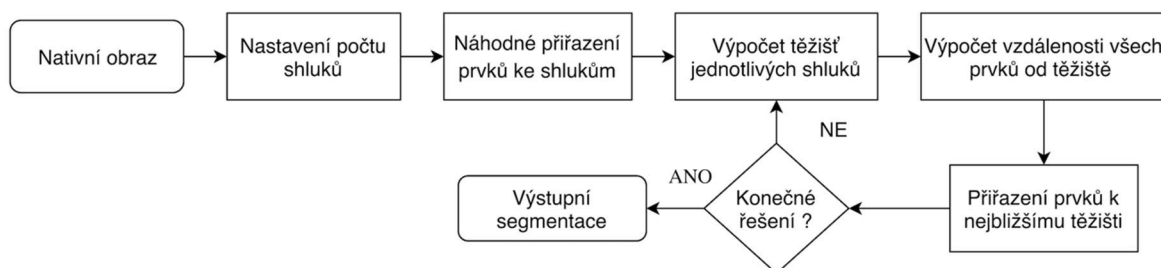
Následující kapitola je věnována čtyřem testovaným algoritmům, výstupní obrazová segmentace je vyhotovena z nativních snímků pro názornou ukázkou. Součástí obrazových dat jsou u algoritmů PSO a GA i jednotlivá grafická vyhodnocení fitness funkce, která udává nejlepší poměr vazby pixelů ke svému shluku. U algoritmu FCM je graficky vyobrazena míra příslušnosti jednotlivých pixelů ke shlukům.

Důležitou součástí této kapitoly je i shrnutí jednotlivých parametrů, které byly nastavovány u algoritmů PSO a GA, jejich popis můžeme vidět v níže uvedených tabulkách. Algoritmy k-means a FCM vzhledem ke své jednoduchosti disponují pouze nastavením počtu segmentačních tříd neboli shluků. Algoritmy PSO a GA disponují širokou škálou nastavení, ta jsou popsána v kapitole níže. Veškeré testování je prováděno pomocí softwaru MATLAB.

5.3.1 K-means (KM)


Jedna z nejpopulárnějších metod používaná v rámci shlukové analýzy. Metoda je schopna účinně oddělit důležité oblasti zájmu od pozadí obrazu, avšak pouze na binární úrovni.

Nazýváme ji tedy metodou s tvrdým přístupem, neboť disponuje přerozdělením jednotlivých obrazových pixelů pouze na binární úrovni.



Obr. 41: Algoritmus metody k-means [vlastní]

Důležitým úkonem před zahájením shlukování je stanovit počet shluků, tedy počet segmentačních tříd, do kterých bude obraz rozdělen. Následně je již každé segmentační třídě přiřazeno těžiště, což je bod v obraze, ke kterému jsou následně agregovány jednotlivé pixely. Přiřazení pixelů k těžištím je realizováno za pomoci metrik vzdálenosti, v tomto případě Euklidovou vzdáleností. V rámci první iterace jsou jednotlivé pixely přiřazeny ke svému těžišti, a to vždy na základě nejmenší vzdálenosti.




Obr. 42: Vlevo nativní snímek, vpravo segmentovaný snímek MRI cév metodou k-means pro 3 shluky [vlastní]

V následujících iteracích dochází k přepočítávání těžišť, to je realizováno jako aritmetický průměr ze všech pixelů ve zvoleném shluku. V poslední fázi dochází ke konvergenci, což signalizuje výsledné řešení rozložení jednotlivých shluků, na druhou stranu, pokud při jednotlivých iteracích dojde ke změně distribuce pixelů, jsou těžiště ještě před výsledným řešením přepočítána.

Segmentovaný snímek do 3 shluků můžeme vidět na Obr. 42. Jedná se o MRI cév v oblasti mozku a krku. Velmi dobře jsou viditelné krční karotidy (shluk se žlutou barvou), kde dochází k velkému průtoku krve. Je patrné, že pokud se na obrázku vyskytuje objekt s vysokou jasovou intenzitou, jako cévy v tomto případě, tak bude při segmentaci vytažen do popředí, což je pro nás žádoucí. Naopak pozadí s nižší jasovou intenzitou je v tomto případě potlačeno [49].

5.3.2 Fuzzy c-means (FCM)

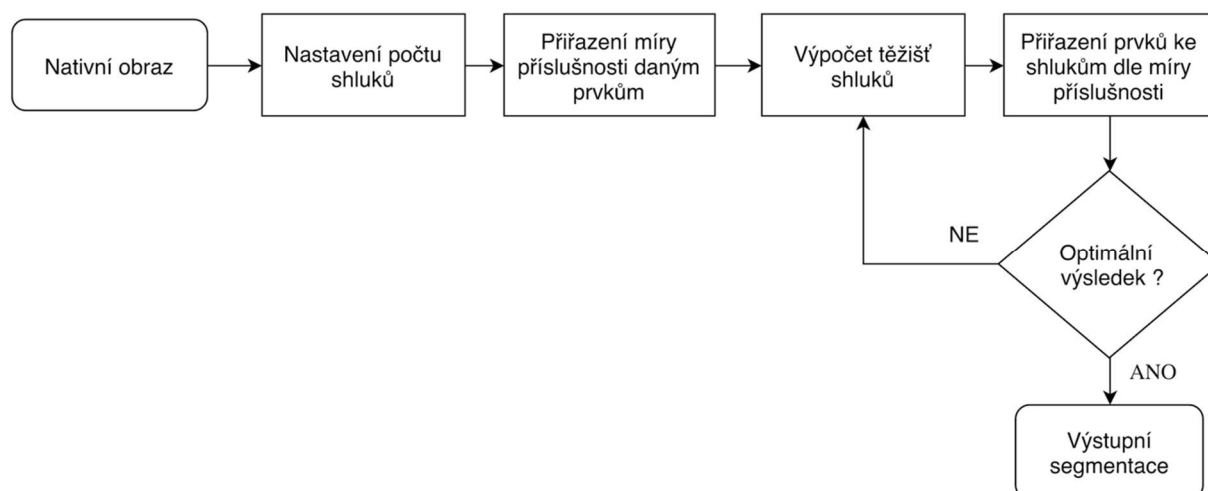
Základní princip algoritmu se podobá metodě k-means, avšak hlavním rozdílem je přístup ve způsobu přerozdělení pixelů k jednotlivým shlukům. FCM již řadíme k metodám, které disponují prvky umělé inteligence, v tomto případě fuzzy logice. Hlavní výhodou je, že ke každému pixelu je přiřazen určitý stupeň členství rozhodující s jakou mírou příslušnosti patří či nepatří k danému shluku, jedná se o tzv. měkké shlukování na rozdíl od předchozího konvenčního k-means shlukování tvrdého. Více je tato problematika probrána v teoretické části práce.



Obr. 43: Segmentovaný snímek MRI cév metodou FCM. Zleva nativní snímek; segmentovaný snímek pro 3 shluky; graf míry příslušnosti pixelů ke shlukům [vlastní]

Stejně jako u metody k-means je i zde v počátku nutné stanovit počet shluků, součástí výstupu je ukázka přerozdělení jednotlivých pixelů ke svým shlukům, kterou můžeme vidět na Obr. 43. Výstup segmentace je graficky znázorněn na obrázku vpravo, kde jsou jednotlivé segmentační třídy reprezentovány barevnými křivkami. Tyto křivky ukazují zastoupení jednotlivých stupňů šedi, v tomto případě se jedná o formát *uint-8*, tudíž rozlišujeme 256 úrovní šedi, kde 0 jsou pixely černé barvy a 255 bílé barvy, všechny ostatní hodnoty jsou jednotlivé stupně šedi.


Na horizontální ose grafu Obr. 43 je vyobrazena hodnota jasové intenzity pixelů, na vertikální poté míry příslušnosti jednotlivých pixelů ke shlukům. Z grafu je jasně čitelné, že pixely černé barvy, tedy pozadí obrazu, jsou zobrazeny červenou křivkou, naopak pixely zobrazující prokrvenou část cévního řečiště vykazující vysokou jasovou intenzitu jsou reprezentovány křivkou modré barvy. Pokud bychom ponechali v obraze pouze křivku modré barvy, tedy pixely s nejvyšší jasovou intenzitou, a ostatní křivky vynulovali, dosáhneme extrakce cévního řečiště, což je další podkapitola této diplomové práce, která bude rozebrána níže.



Obr. 44: Algoritmus metody FCM [vlastní]

5.3.3 Particle Swarm Optimization (PSO)

PSO je stochastická optimalizační technika, je jedním z hlavních představitelů evolučních algoritmů, které nacházejí inspiraci v chování hejn či skupin zvířat přírodní populace, podrobněji je algoritmus opět rozebrán v teoretické části práce. Příkladem může být scénář, ve kterém hejno ptáků hledá v určité oblasti potravu. Všichni ptáci nemohou vědět, kde přesně se jídlo nachází, ale s každou další iterací postupně zjistí, kde jídlo je. Nejlepší strategií bude sledovat ptáka, který je blízko jídla a také jaká byla jeho nejlepší předchozí pozice.

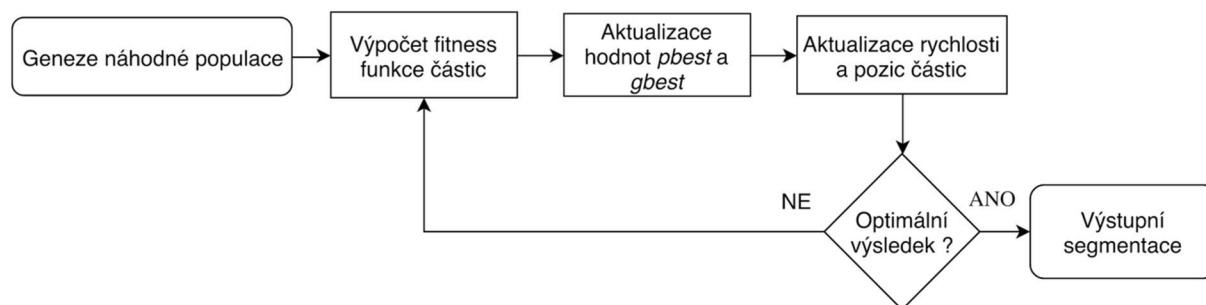


Obr. 45: Segmentovaný snímek CT cév metodou PSO zleva pro 3; 7 shluků [vlastní]

Pokud si toto přirovnání hejna ptáků převedeme do oblastí shlukové analýzy a segmentace obrazu, dostáváme algoritmus, který pomocí prohledávání jednotlivých pixelů obrazu dokáže s velkou přesností přerozdělit tyto pixely ke svým shlukům. Díky tomu jsme schopni s každou další iterací dosáhnout co nejkvalitnějšího řešení.

V počátku je vytvořena náhodná populace částic, které jsou předurčeny pro výsledné řešení. Následně je vypočítána fitness funkce pro každou z částic, aby bylo zjištěno, která z nich se nejbližší dostala ke konečnému řešení. Dále do algoritmu vstupují dvě důležité hodnoty, *pbest* reprezentující nejlepší hodnotu získanou předchozí částicí a *gbest* reprezentující nejlepší možnou hodnotu získanou kteroukoliv částicí z celého hejna.

Poslední z kroků je aktualizace jednotlivých pozic a rychlosti částic na základě dříve zjištěných parametrů. Konečným výsledkem je segmentace obrazu, která dosáhla co nejlepšího výsledku fitness funkce či nastavení vstupních parametrů [45].



Obr. 46: Algoritmus metody PSO [vlastní]

5.3.4 Fitness funkce

Kvalita segmentace je u jednotlivých snímků vždy variabilní, to znamená, že i výsledná hodnota fitness funkce bude rozdílná. Funkce souvisí s vnitřním rozptylem každého shluku.


Pokud pixely uvnitř shluku vykazují maximální podobnost, bude jejich vnitřní rozptyl minimální. Pro fitness funkci tedy platí, že pokud dosáhneme v součtu všech shluků co nejmenšího rozptylu mezi jednotlivými pixely, dosáhneme lepšího výsledku fitness funkce, viz. vzorec (5.3), kde x reprezentuje dané pixely a \bar{x} těžiště.

Hodnota funkce je pro nás velmi důležitá, protože reprezentuje variabilitu dat v daném shlukovaném modelu. Pokud tedy segmentační technika dokáže co nejvíce minimalizovat rozptyl mezi pixely a daným shlukem, tak jsme schopni eliminovat prudké jasové změny a tím i dosáhnout lepší segmentace [52].

$$Var(X) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2, \quad (5.3)$$

Znázornění minimalizace hodnoty fitness funkce je ukázáno na Obr. 47. Osa x reprezentuje počet iterací, což je hodnota, která udává, kolikrát algoritmus znovu přepočítá jednotlivé kroky a vyhodnotí novou hodnotu fitness funkce, která je vyobrazena na ose y .

Je vidět, že graf vykazuje klesající hodnoty se zvyšujícím se počtem iterací, kde při určité hodnotě již nedochází ke zlepšení funkce. Důležité je v tomto případě najít optimální počet iterací v kontextu nejlepších hodnot fitness funkce, aby zbytečně nedocházelo k vysoké výpočetní náročnosti.

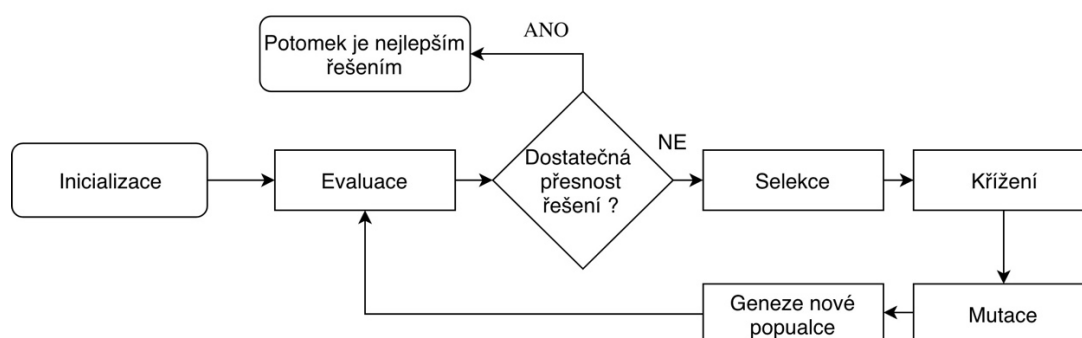


Obr. 47: Grafické znázornění hodnoty fitness funkce v závislosti na počtu iterací, metoda PSO [vlastní]

5.3.5 Genetický algoritmus (GA)


Téměř každý algoritmus disponuje parametry, které slouží k řízení co nejlepšího výsledku segmentace obrazu, viz Obr. 49. GA je však schopen jakožto mnoho metod založených na umělé inteligenci tyto parametry v průběhu dynamicky měnit, aby dosáhl co možná nejpresnějšího výsledku. V této kapitole je zmíněn základní princip metody v souvislosti se shlukováním, podrobnější popis je uveden v teoretické části této práce [50, 51].

Proces výpočtu GA lze sumarizovat do dvou kroků. Prvním krokem je volba počáteční populace, tedy počtu možných vstupních řešení spolu s ostatními parametry, jako je počet iterací, způsob křížení, mutace. Velikost populace určuje, kolik jednotlivců je v každé generaci. Při vysokém počtu populace genetický algoritmus důkladněji prohledává prostor řešení, čímž zvyšuje pravděpodobnost úspěchu algoritmu, avšak i rapidně se prodlužuje výpočetní čas. Při každé iteraci provádí genetický algoritmus řadu výpočtů na současné populaci, aby vytvořil novou populaci. Každá následná populace se nazývá nová generace [46].



Obr. 48: Algoritmus metody GA [vlastní]


Druhým krokem je již samotné hodnocení kvality segmentace na základě fitness funkce, která udává co nejlepší postavení pixelů jednotlivých shluků. Pokud není dosaženo požadovaného výsledku, je na základě operátorů křížení, mutace a selekce vytvořena rekombinace stávající populace, což vytvoří nové silnější jedince. Tyto kroky jsou neustále opakovány dle Obr. 48, dokud není dosaženo nejlepší fitness funkce či dosažení nastavených parametrů [46].



Obr. 49: GA segmentace CT cév s nastavením pro 5 a 10 shluků. Velikost populace: 50; počet generací: 20 [vlastní]

Princip minimalizace hodnoty fitness funkce zůstává stejný jako u metody PSO. Na Obr. 50 můžeme vidět graf, kde na ose x je počet generací, které ukazují stejně jako parametr iterace u PSO na počet kroků algoritmu, při kterém bude vygenerována nová populace jedinců. Graf vykresluje dvě křivky, první z nich značí nejlepší a druhá průměrnou hodnotu fitness funkce.

Opět je možné pozorovat, že dochází k minimalizaci fitness funkce, kde její ustálení je zhruba okolo generace 40, následně již nabývá konstantního průběhu a je neměnná.



Obr. 50: Grafické znázornění hodnoty fitness funkce v závislosti na počtu generací, metoda GA [vlastní]

5.4 Nastavení testovaných parametrů

Celkové testování bylo pro zjednodušení rozděleno na dvě části, konkrétně robustní analýzu a testování extrakce tkání. Robustní testování zahrnuje metody KM, FCM a GA s výše nastavenými parametry v Tabulka 5. Robustní testování tvoří hlavní část této práce, kde je konvenční metoda KM srovnávána s metodami, které disponují prvky umělé inteligence FCM a GA, kde u GA bylo kromě počtu shluků a populace testováno dodatečné nastavení obsahující další vstupní parametry ovlivňující segmentaci obrazu.

Druhou částí je testování extrakce tkání, které zahrnuje všechny výše zmíněné metody KM, FCM a GA, a navíc je zde testována i metoda PSO. Pro zjednodušení vzhledem k velkému nároku na výpočetní čas byla u metody GA a PSO vybrána dvě počáteční nastavení, a to populace 100

a generace/iterace 20. Ostatní dodatečná nastavení v tomto případě nebyla použita, počet shluků byl volen stejně tedy 3, 5, 7, 10 a 12.

V počátku je nutno definovat, že metody KM a FCM disponují pouze nastavením počtu shluků, tudíž i následná analýza je postavena pouze na tomto vstupním parametru. U sofistikovanějších metod GA a PSO jsou nastavení různá a existuje jich nespočetně mnoho, většina těchto nastavení je vyobrazena v Tabulka 5. Dle Obr. 51 v počátku volíme již zmíněný počet shluků, ten je nastavován na hodnoty 3, 5, 7, 10 a 12 u všech testovaných metod. Další částí je zvolení typu šumu, na výběr je Gaussův, Salt&pepper a Speckle šum, intenzita šumu je volena dle Tabulka 4 v kapitole 5.2.

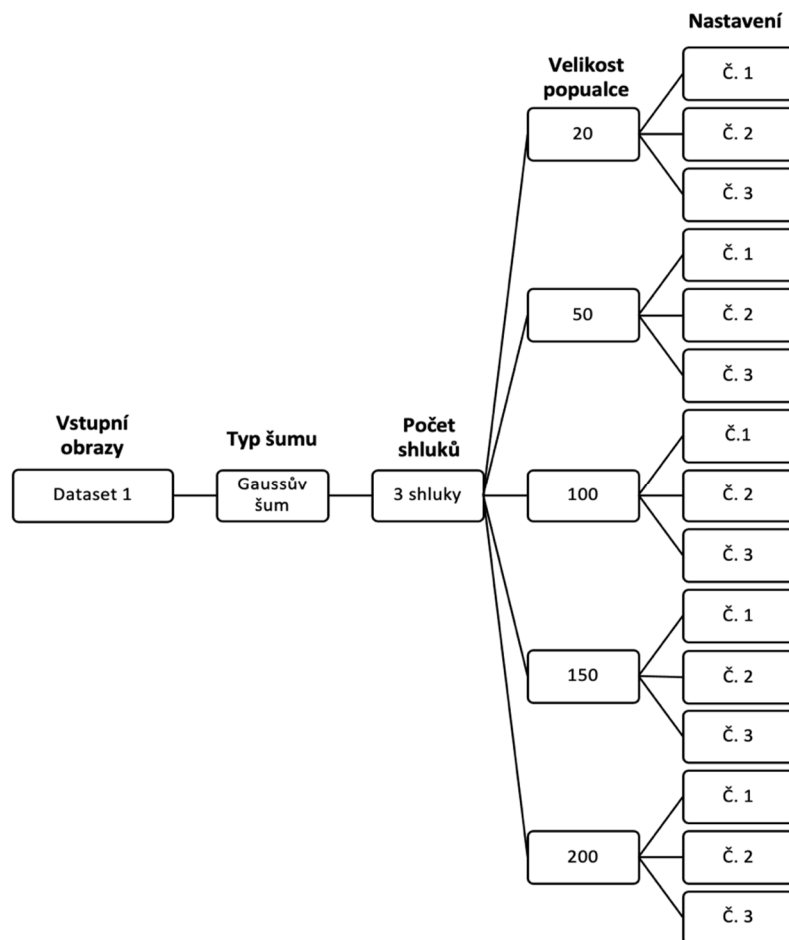
Tabulka 5: Nastavení testovaných parametrů pro všechny metody [vlastní]

Dataset	Šum	Shluky	Populace	Generace	Frakce křížení	Elitní počet	Typ selekce	Nastavení
1; 2; 3; 4	Gaussův; Salt&Pepper; Speckle;	3; 5; 7; 10; 12	20	10	0.5	2	selectionroulette	1
				20	0.5	5	selectionstochunif	2
				40	0.5	8	selectiontournament	3
			50	10	0.5	2	selectionroulette	1
				20	0.5	5	selectionstochunif	2
				40	0.5	8	selectiontournament	3
			100	10	0.5	2	selectionroulette	1
				20	0.5	5	selectionstochunif	2
				40	0.5	8	selectiontournament	3
			150	10	0.5	2	selectionroulette	1
				20	0.5	5	selectionstochunif	2
				40	0.5	8	selectiontournament	3
			200	10	0.5	2	selectionroulette	1
				20	0.5	5	selectionstochunif	2
				40	0.5	8	selectiontournament	3

U GA bylo na základě zkušebních testů vybráno několik vstupních parametrů podílejících se na optimální obrazové segmentaci. Populace neboli počáteční počet vstupních řešení je parametr, ze kterého je následně pomocí vnitřní funkce algoritmu postupně vybráno nejlepší výsledné řešení. Velikost populace je volena v hodnotách 20, 50, 100, 150 a 200, při vyšších hodnotách populace již dochází k velmi vysokým výpočetním a časovým nárokům.

Generace je parametr definující počet iterací v jednotlivých krocích, jeho hodnoty jsou nastaveny na 10, 20 a 40. Spolu s nastavením parametru generace je vždy ke každé hodnotě přidruženo dodatečné nastavení, to se skládá z frakce křížení, což je parametr, který určuje, jaká část současné populace se bude podílet na křížení pro vytvoření populace nové. Jako nejeefektivnější byla pro segmentaci obrazu vybrána hodnota 0,5, a to pro všechny níže zmíněné testy. Předposledním parametrem je elitní počet označující počet jedinců, kteří disponují nejlepšími hodnotami fitness funkce a jsou automaticky převedeni do další generace.

Hodnota parametru je vždy vztažena k počtu populace a je volena v počtu 2, 5 a 8. Posledním parametrem je volba typu selekce, tato problematika je již rozebrána v teoretické části práce, přičemž je vybíráno mezi Ruletovou, Stochastickou a Turnajovou selekcí dle Tabulka 5. Posléze již dochází k samotné implementaci segmentačních algoritmů a následnému testování.



Obr. 51: Nastavení GA testovaných parametrů pro Gaussův šum, dataset 1 a 3 shluky [vlastní]

Na Obr. 51 je viditelný diagram zobrazující princip testování a nastavení jednotlivých částí a parametrů. Kvůli rozsáhlému testování je ukázka diagramu realizována pouze na jeden typ datasetu, šumu a počet shluků. Velikost populace je již vyobrazena ve všech nastavovaných hodnotách, stejně jako nastavení č. 1, 2 a 3. Kompletní testované parametry jsou viditelné v Tabulka 5. Na níže zmíněném Obr. 52 jsou v každé z tabulek vypsána jednotlivá nastavení metody PSO a GA. Všechny parametry byly nastaveny a realizovány pomocí vestavěné funkce MATLABu.

Nastavení, která byla testována v rámci diplomové práce, jsou vyznačena šedě, jednalo se především u metody PSO o parametr *MaxIterations* udávající maximální počet iterací, druhý parametr poté byla hodnota počáteční populace *Swarm Size*.

U metody GA byly nastavovány 4 parametry, první dva z nich opět definují velikost populace *PopulationSize* a počet generací *MaxGeneretions*. Dodatečné nastavení, jak již bylo zmíněno výše, se skládá z frakce křížení *CrossoverFraction*, elitního počtu jedinců, kteří jsou předurčeni automaticky přejít do další generace *EliteCount*. Posledním z parametrů je funkce určující typ selekce *SelectionFcn*, kde jednotlivé selekce jsou podrobně popsány v teoretické části práce, konkrétně byly nastavovány selekce Pořadová, Ruletová a Turnajová. V pravém sloupci obou tabulek jsou vypsány testované hodnoty.

Nastavení algoritmu PSO				Nastavení algoritmu GA			
Parametr	Popis	Výchozí nastavení	Testování	Parametr	Popis	Výchozí nastavení	Testování
<i>CreationFcn</i>	Funkce, která vytvoří počáteční roj částic.	<i>pswcreationuniform</i>		<i>CreationFcn</i>	1 x Funkce, která vytváří počáteční populaci.	<i>gacreationuniform</i> <i>gacreationlinearfeasible</i>	
<i>FunctionTolerance</i>	Dojde k ukončení další iterace, pokud je relativní změna nejlepší hodnoty objektivní funkce menší než tento parametr.	10^{-6}		<i>ConstraintTolerance</i>	Určuje proveditelnost s ohledem na nelineární omezení.	10^{-6}	
<i>HybridFcn</i>	Funkce, která pokračuje v optimalizaci za pomoci hybridních funkcí.	<i>fmincon</i> , <i>fminsearch</i> , <i>fminunc</i> , <i>patternSearch</i>		<i>CrossoverFcn</i>	Funkce, kterou algoritmus používá k vytváření křížených potomků.	<i>crossoverscattered</i> <i>crossoverintermediate</i> <i>crossoverheuristic</i> <i>crossoversinglepoint</i> <i>crossovertwopoint</i> <i>crossoverarithmetic</i>	
<i>InertiaRange</i>	Dvoupřvkový vektor se stejnými hodnotami znamének. Poskytuje horní a dolní mez adaptivní setrvačnosti.	[0,1,1,1]		<i>CrossoverFraction</i>	Zlomek populace v příští generaci, bez elitních potomků, který vstupuje do funkce křížení.	0,8	[0,5]
<i>InitialSwarmMatrix</i>	Počáteční či částečná populace částic zapsána do matice.	-		<i>FitnessLimit</i>	Pokud funkce fitness dosáhne hodnoty <i>FitnessLimit</i> , algoritmus se zastaví.	Nekonečno	
<i>InitialSwarmSpan</i>	Počáteční rozestup pozic částic	2000		<i>EliteCount</i>	Kladné celé číslo určující, kolik jedinců v současné generaci je zaručeno, že přežijí do další generace.	Kladná hodnota odvozen z velikosti populace násobenou konstantou 0,05	[2; 5; 8]
<i>MaxIterations</i>	Maximální počet iterací algoritmu.	200 x počet proměnných	[40]	<i>PopulationSize</i>	Velikost počáteční populace	Kladná hodnota	[20; 50; 100; 150; 200]
<i>MaxStallIterations</i>	Iterace je ukončena když je relativní změna hodnoty nejlepší objektivní funkce v průběhu posledních iterací.			<i>SelectionFcn</i>	Funkce, která vybírá rodiče křížených a mutovaných potomků.	{'selectionstochastic'} {'selectiontournament'} {'selectionuniform'} {'selectionroulette'}	{'selectiontournament'} {'selectionuniform'} {'selectionroulette'}
<i>MaxStallTime</i>	Maximální žiselná hodnota času v sekundách, která udává délku vylepšení objektivní funkce.	nekonečno		<i>MutationFcn</i>	Funkce, která produkuje mutované potomky.	{'mutationgaussian'} {'mutationadaptfeasible'} {'mutationuniform'}	
<i>MaxTime</i>	Maximální čas v sekundách, po který běží částice.	nekonečno		<i>MaxStallTime</i>	Algoritmus se zastaví, pokud nedojde ke zlepšení v objektivní funkci po dobu určitého času	Kladná hodnota	
<i>MinNeighborsFraction</i>	Minimální velikost adaptivního sousedství.	[0;1]		<i>MaxGenerations</i>	Maximální počet iterací před zastavením algoritmu.	Kladná hodnota	[10; 20; 40]
<i>ObjectiveLimit</i>	Objektivní hodnota určující kritérium pro zastavení.	nekonečno		<i>FitnessScalingFcn</i>	Funkce, která upravuje hodnoty fitness funkce.	'fitscalingrank' 'fitscalingshiftdown' 'fitscalingprop' 'fitscalingtop'	
<i>SelfAdjustmentWeight</i>	Vážení nejlepší polohy částice při nastavování její rychlosti.	1,49		<i>InitialPopulationRange</i>	Matice nebo vektor určující rozsah jednotlivců v počáteční populaci.	Kladná hodnota	
<i>SocialAdjustmentWeight</i>	Vážení nejlepší polohy okolí při upravení rychlosti částice.						
<i>SwarmSize</i>	Počet částic v roji	>1	[100]				

Obr. 52: Vlevo parametry funkce metody PSO, vpravo metody GA [vlastní]

6 Evaluační metriky

Metrik pro výslednou evaluaci segmentovaných obrazů existuje nespočetně mnoho, pro následující vyhodnocení byly vybrány pouze níže uvedené metriky. V rámci porovnání jednotlivých snímků je vždy výsledek postaven na vzájemné podobnosti segmentovaného obrazu ovlivněného aditivním šumem vůči nativnímu segmentovanému obrazu, tzv. zlatého standardu. Všechny výsledné hodnoty jsou nadále zpracovány a vyhodnocovány v níže uvedené kapitole.

6.1.1 Korelace

Jedním z prvních parametrů pro objektivní srovnání dvou obrazů je korelace, kde míra korelace je dána korelačním koeficientem značeným písmenem r . Koeficient může nabývat hodnot od -1 do 1, přičemž hodnota 1 značí nejvyšší možnou shodu obou obrazů. Principem je vypočítání rozdílnosti hodnot intenzity každého z pixelů v obou obrazech vůči celkové průměrné intenzitě celého obrazu. Proměnné m a n reprezentují pozici pixelu v obraze. Výpočet metriky je znázorněn vzorcem (6.1), kde \bar{A} je průměrná hodnota obrazu A a \bar{B} je průměrná hodnota obrazu B .

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \quad (6.1)$$

6.1.2 Střední kvadratická chyba

Český název vychází z anglického mean square error (MSE). V současné době jeden z konvenčních a jednoduchých způsobů pro diferenciaci dvou obrazů. Jedná se o výpočet průměru součtu čtverců dvou rozdílných obrazových pixelů. Hodnota MSE označuje průměrný rozdíl pixelů v celém obraze. Vyšší hodnota MSE znamená větší rozdíl mezi původním obrazem a zpracovaným obrazem.

Nedostatkem metody je rozdíl v odstínech šedi, kde každá hodnota, může nabývat podobné váhy. V případě, že je pozadí obrazu zašuměno, střední kvadratická chyba vyhodnotí vyšší MSE, i když je objekt v obraze dobře rozpoznatelný. Výpočet metriky je znázorněn vzorcem (6.2).

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (6.2)$$

kde:

n je počet pixelů obrazu,

\hat{y}_i je predikovaná hodnota,

y_i je aktuální hodnota.

6.1.3 SSIM


Index strukturální podobnosti, z *angl. Structural Similarity Index*, je založen na výpočtu tří komponentů obrazu, a to jasů, kontrastu a struktury. Celkový index je multiplikativní kombinací těchto tří komponentů. Výsledek je v rozmezí od -1 do 1 a stejně jako u korelace, hodnota 1 reprezentuje duplicitní obrazy. Výpočet metriky je znázorněn vzorcem (6.3), kde μ značí vážený průměr obrazů x a y , σ odpovídá kovarianci x a y , C je definováno jako rozsah hodnot pixelů.

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (6.3)$$

6.1.4 Jaccard koeficient

Jaccardův koeficient známý také jako IoU (Intersection-Over-Union) je jednou z nejčastěji používaných metrik v určení výstupní kvality segmentace. Jedná se o velmi přímočarou metriku, která je mimořádně efektivní. Jaccard koeficient zdůrazňuje podobnost mezi konečnými sadami pixelů a je formálně definována jako velikost průsečíku dělená velikostí sjednocení jednotlivých sad pixelů. Tato metrika se pohybuje v rozmezí 0 až 1, přičemž 0 znamená žádné překrytí a 1 znamená dokonale překrývající se segmentaci. Výpočet metriky je znázorněn vzorcem (6.4) kde A reprezentuje oblast zlatého standartu a B oblast segmentovaného snímku.

$$\text{Jaccard} = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} \quad (6.4)$$




Obr. 53: Grafická ukázka principu výpočtu Jaccard koeficientu [47]

6.1.5 Dice koeficient

Dice koeficient, celým názvem Sørensen Dice, je koeficientem dvojnásobné plochy překrytí dělený celkovým počtem pixelů v obou obrazech. Dice koeficient je velmi podobný Jaccardovu. Oba jsou pozitivně korelované, což znamená, že když jeden vykazuje, že model A je lepší než model B v hodnocení segmentace, pak druhý vykazuje totéž. Stejně jako Jaccard koeficient se oba pohybují v rozmezí od 0 do 1, přičemž 1 znamená největší podobnost mezi předpovězenou a pravdivou predikcí. Výpočet metriky je znázorněn vzorcem (6.5), kde A reprezentuje oblast zlatého standartu a B oblast segmentovaného snímku.

$$Dice = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (6.5)$$



Obr. 54: Grafická ukázka principu výpočtu Dice koeficientu [47]

7 Výsledky testování na reálných datech

Kapitola obsahuje analýzu veškerých datových výstupů hodnotící robustnost a odolnost jednotlivých metod vůči parazitnímu šumu. Testování zahrnuje čtyři datasety o 10 snímcích, dohromady tedy 40 snímků různého původu. Výstupem práce jsou především grafické, obrazové a číselné analýzy pocházející z objektivních evaluačních metrik popsanych v kapitole 6.

V první části bylo provedeno hlavní robustní testování na všech 40 snímcích ovlivněných šumem a segmentovaných metodou KM, GA a FCM. Veškerý popis a nastavení metod jsou podrobně uvedeny v kapitolách výše. V grafických zhodnoceních je srovnávána především robustnost zmíněných metod, zvolený počet shluků, hodnota počáteční populace u GA a nastavení u GA.

Druhá část je věnována testování extrakcí a modelování tkání. Zde je využito třech reprezentativních snímků, u kterých byla provedena segmentace pomocí algoritmů KM, GA, FCM a PSO. Po vytvoření segmentovaného snímku následuje extrakce oblasti zájmu, která současně slouží jako vstupní oblast pro evaluaci.

Celkem pro obě části testování bylo vygenerováno přes 150 GB segmentovaných snímků, které byly využity pro následnou analýzu a srovnání. Všechna výstupní data jsou uložena v příloze této diplomové práce a jsou popsána jednotlivými hlavičkovými soubory. Pro velmi vysoký objem výstupních dat jsou v této kapitole vybrány jen některé z výstupních analýz u dvou datasetů, zbylé dva datasety jsou hodnoceny pouze slovně.

7.1 Výsledky testování snímků CT cév

Výpočetní tomografie je schopna velmi přesně zobrazit vyšetřovanou tkáň a na základě její hustoty ji separovat od pozadí a ostatních částí lidského těla. Snímky CT cév pocházejí z CT angiografie, což je modalita pro vyšetření cévního řečiště, nejčastěji s pomocí kontrastní látky, která zajistí zastínění vyšetřované cévy.

Většina snímků je tvořena tmavými pixely reprezentujícími pozadí a nezájmovou oblast snímku. Cévní řečiště zobrazené šedou barvou je fyziologické, velmi světlé pixely obrazu ukazují na patologické projevy, nejčastěji kalcifikaci. Pro ukázkou jsou vybrány jen reprezentativní obrazové a grafické výstupy, ostatní výstupy je možné vidět v přílohách této diplomové práce.



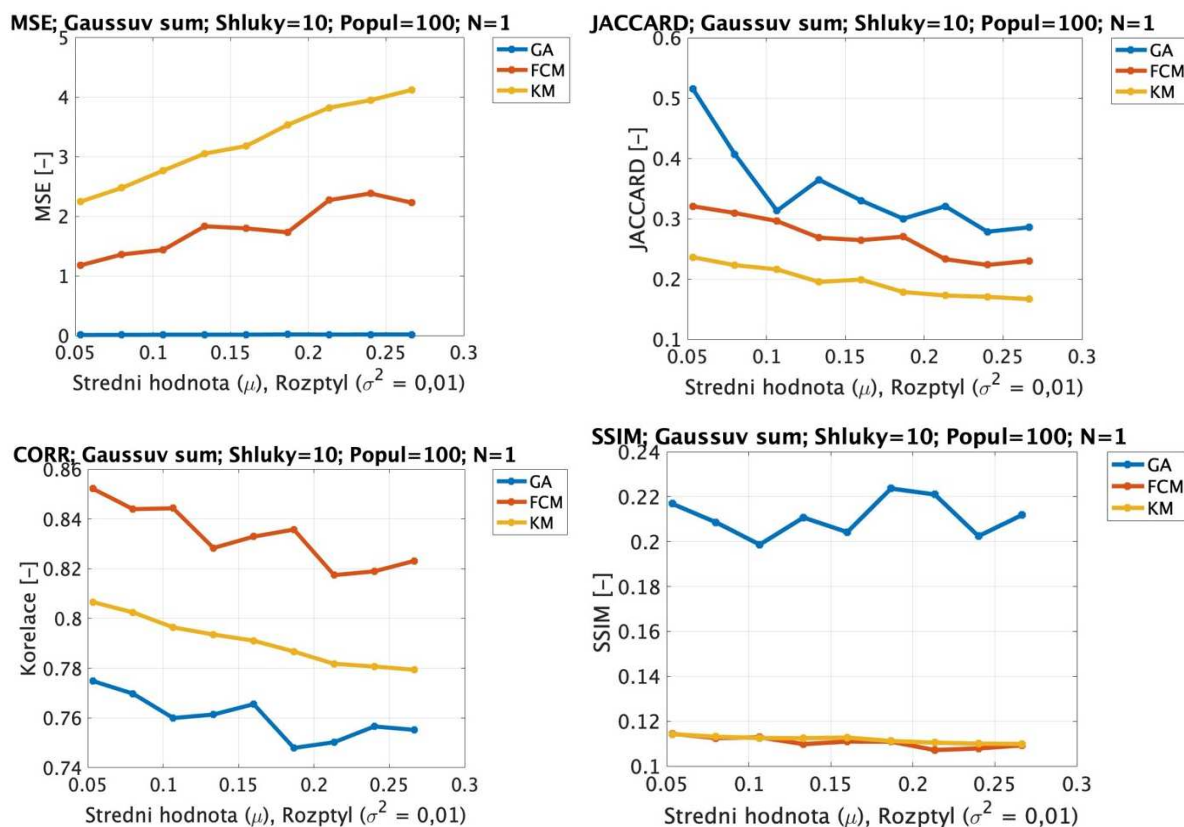
Obr. 55: Ukázka implementace Gaussova šumu na snímek CT cév. Zleva nativní snímek; zašuměný snímek $\mu=0,1$, $\sigma^2=0,01$ [vlastní]

Na Obr. 56 můžeme vidět již segmentované snímky části dolní končetiny ovlivněné Gaussovým šumem. Nastavení pro 5 shluků dokáže s přesností odlišit cévy od ostatních tkání. Na první pohled jsou snímky totožné, avšak pokud se více zaměříme, je možné vidět mírnou odlišnost na snímku GA v podobě barevné mapy, kde je cévní řečiště lépe odlišitelné od pozadí snímku.




Obr. 56: Ukázka segmentačních metod pro 5 shluků, Gaussův šum $\mu=0,1$, $\sigma^2=0,01$. Zleva metoda: KM; FCM; GA [vlastní]

První z grafických vyhodnocení je vidět na Obr. 57. Srovnání metod je realizováno pro snímky o 10 shlucích ovlivněné Gaussovým šumem. Velikost populace pro GA je zvolena na hodnotu 100 s dodatečným nastavením čísla 1. Již na prvním grafu u parametru MSE je jasně patrná robustnost GA vůči ostatním metodám, podobné hodnoty vykazuje GA i u parametru JACCARD či SSIM. Korelace však v tomto případě ukazuje hodnoty zcela opačné, jako nejlepší metoda vychází FCM a KM, jako druhá v pořadí a s nejhorší trendovou linií je metoda GA. Důležité je však podotknout, že rozdíl hodnot korelace mezi metodami je v hodnotách desetín, kdežto například u MSE je v jednotkách.



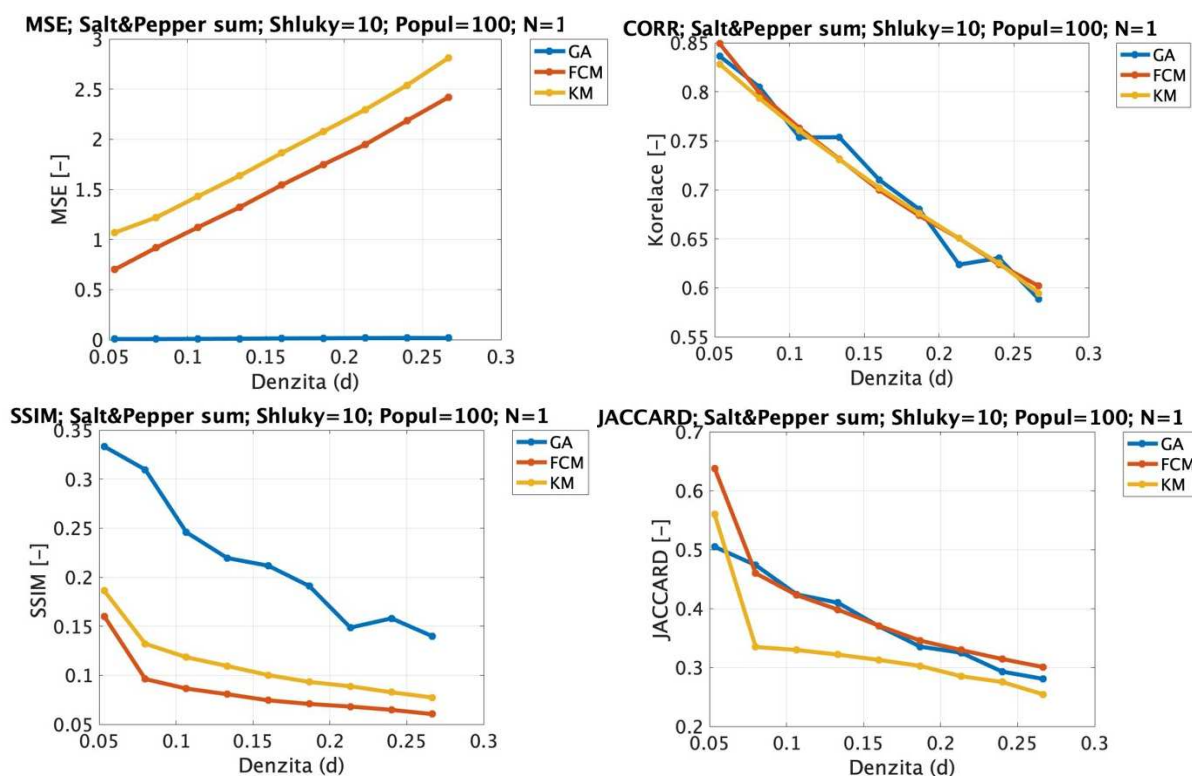
Obr. 57: Analýza robustnosti CT cév pro Gaussův šum, 10 shluků a metody KM, FCM a GA [vlastní]



Obr. 58: Ukázka segmentace pro 5 shluků, 100 populace a Gaussův šum. Zleva: zašuměný snímek $\mu=0,2$, $\sigma^2=0,01$; segmentace metodami KM; FCM; GA [vlastní]


Na následujícím Obr. 59 jednotlivé výstupy odpovídají nastavení pro Salt&pepper šum a 10 shluků. Parametr MSE jasně ukazuje konstantní průběh křivky pro GA držící se v hodnotách blízkých nule. Na druhou stranu KM vykazuje v rámci parametru MSE vysokou chybovost, FCM se drží mezi nimi, avšak také s vyšší mírou chybovosti.

Dle korelace a JACCARD parametru je zjevné, že trendy grafů jsou téměř duplicitní s klesajícím průběhem díky zvyšující se hodnotě impulsního šumu. SSIM jednoznačně ukazuje na robustnost GA. Korelace vykazuje pro všechny metody klesající trend v závislosti na zvyšující se intenzitě šumu. Na rozdíl od SSIM však GA koreluje s ostatními metodami a nevykazuje lepší výsledek.




Obr. 59: Analýza robustnosti snímků CT cév pro Salt&pepper šum, 10 shluků a metody KM,FCM a GA [vlastní]

Následující Obr. 60 ukazuje CT snímek cév z oblasti hrudníku a břicha. Shluk žluté barvy v levé části všech snímků reprezentuje prokrvenou oblast cév. Vlevo lze vidět zašuměný snímek šumem Salt&pepper o intenzitě $d=0,2$. Další snímky reprezentují již jednotlivé segmentace rozdílných metod. Můžeme si povšimnout, že mezi KM a FCM segmentací nejde pouhým okem rozeznat rozdíl. Snímek vpravo získaný za pomoci metody GA již vykazuje určitou odlišnost, jedná se především o rozdílnou barevnou mapu okolo cévy.



Obr. 60: Ukázka segmentačních metod pro 5 shluků, 100 populace a Salt&pepper šum. Zleva: Zašuměný snímek $d=0,2$; segmentace KM; segmentace FCM; segmentace GA [vlastní]

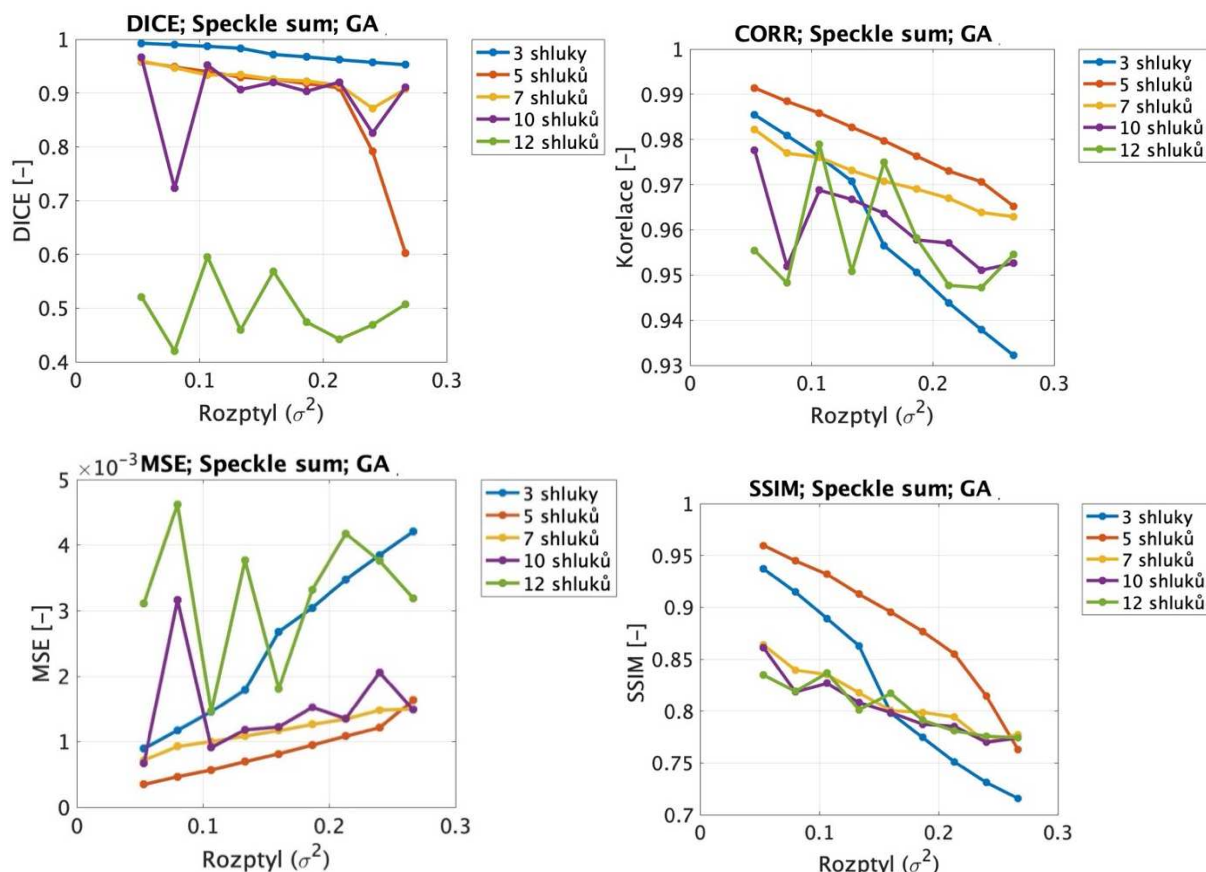


Obr. 61: Analýza robustnosti snímků CT cév, Speckle šum, 10 shluků a metody KM, FCM a GA [vlastní]

Grafické vyhodnocení evaluačních parametrů pro Speckle šum a 10 shluků, viz Obr. 61 vykazuje ve většině případech vyšší robustnosti GA nad KM a FCM. Výjimkou je parametr korelace, kde můžeme vidět v počátku propad, který je v oblastech nízkých hodnot šumu. Trend grafu pokračuje s podobným průběhem jako KM a FCM, avšak s nejhorším výsledkem.

Parametr MSE pro GA vykazuje téměř konstantní trend blíží se nulovým hodnotám střední kvadratické chyby. Metody FCM a KM pro MSE parametr nabývají rostoucích hodnot, konkrétně metoda KM vykazuje nejvyšší chybovost, FCM téměř koreluje s KM. Dle SSIM a JACCARD je viditelné,

že pro Speckle šum je nejlepší volbou segmentace GA. V obou případech totiž nabývá nejvyšších hodnot. V grafu parametru SSIM vykazuje KM vyšší hodnoty oproti FCM, jedná se však jen o desetiny, stejně jako u parametru JACCARD, kde můžeme hovořit o rozdílu v setinách.




Obr. 62: Analýza robustnosti snímků CT cév dle počtu shluků, pro Speckle šum a metodu GA [vlastní]

Počet shluků je bezesporu velmi důležitý počáteční parametr, díky kterému jsme schopni z obrazu odlišit důležité oblasti zájmu. V případě datasetu CT cév byla provedena analýza srovnání všech testovaných počtů shluků v kontextu variabilních šumových podmínek. V tomto případě, viz Obr. 62, se konkrétně jedná o Speckle šum a metodu GA.

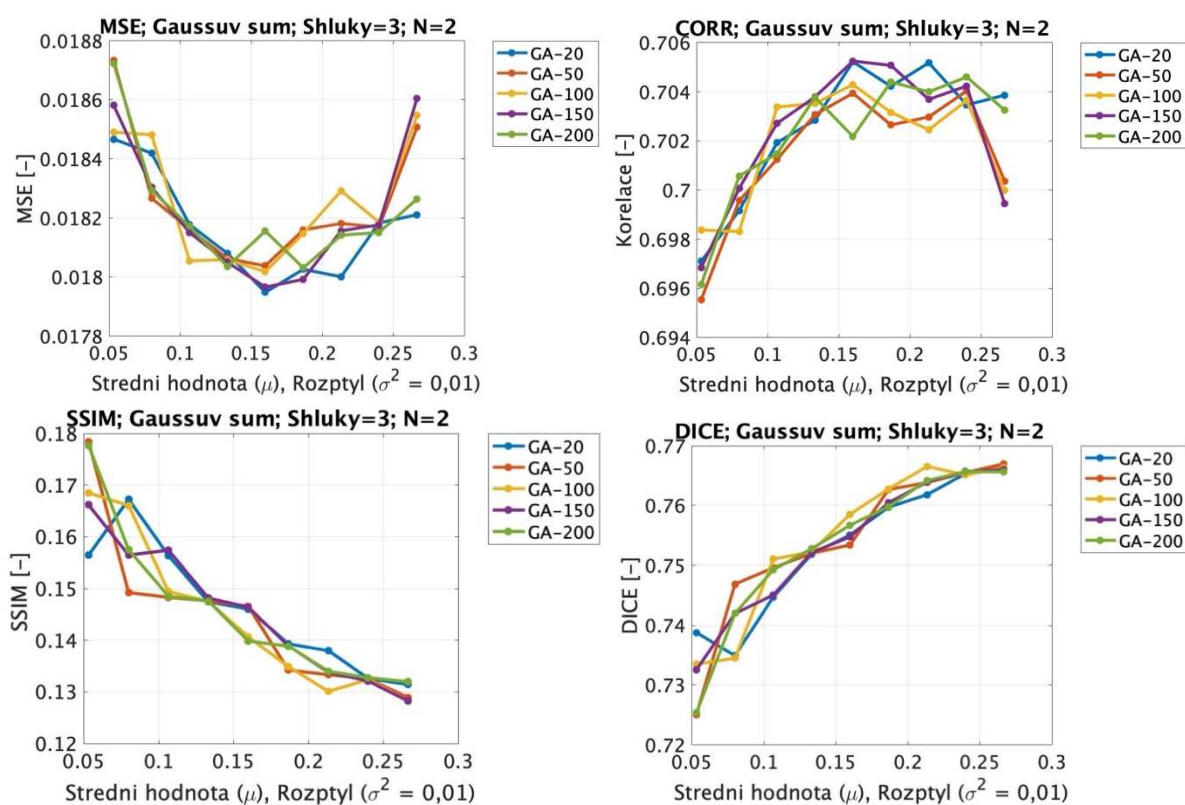
Většina evaluačních parametrů grafů vykazuje variabilitu výsledných hodnot. Dle parametru CORR, SSIM a MSE vykazuje křivka pro 5 shluků nejlepší výsledek, u parametru DICE se jeví tato křivka jako druhá nejlepší. Nastavení pro 3, 7 a 10 shluků se v kontextu všech parametrů jeví jako průměrné, pouze u DICE trend pro 3 shluky nabývá nejvyšších hodnot.

Zvolení počtu 12 shluků má ve všech grafech skokový trend a zároveň nabývá nejhorších hodnot evaluačních parametrů. Pokud bychom chtěli nastavit optimální počet shluků pro snímky CT cév ovlivněné Speckle šumem, je vhodné volit hodnotu okolo 5 shluků. Při vyšších nastaveních již dochází k velké chybovosti, neboť nejsou rozeznávány další struktury obrazu, nýbrž jen parazitní šum.



Obr. 63: Ukázka snímků CT cév se Speckle šumem. Horní řada snímků reprezentuje zleva nativní snímek; segmentace pro 3 shluky; 5 shluků, dolní řada segmentaci pro 7; 10; 12 shluků [vlastní]


Na Obr. 63 je možné reálně porovnat jednotlivá nastavení počtu shluků. V horní řadě je zleva nativní snímek CT cév v oblasti pánve, uprostřed je snímek pro nastavení 3 shluků, vpravo pro 5 shluků, který vykazuje nejlepší parametry evaluačních metrik. Spodní řada snímků ukazuje nastavení pro 7, 10 a 12 shluků.



Obr. 64: Analýza robustnosti snímků CT cév dle populace, pro Gaussův šum, 3 shluky a metodu GA [vlastní]


GA algoritmus vyžaduje pro korektní segmentaci několik vstupních parametrů, hlavním z nich je počáteční populace. V této práci je postupně testováno pět nastavení populací, které jsou vyobrazeny na Obr. 64 v závislosti na parazitním Gaussově šumu.

Všechny evaluační parametry vykazují téměř duplicitní trendy s mírnými záškuby. Nelze tedy s jistotou stanovit velikost populace, která by zlepšovala výslednou segmentaci. Nutné je podotknout, že se zvyšujícím se počtem populace rapidně narůstá výpočetní čas GA. Nejlepším nastavením se v tomto případě jeví populace okolo 20, která dosáhne kvalitní segmentace spolu s nižším výpočetním časem.



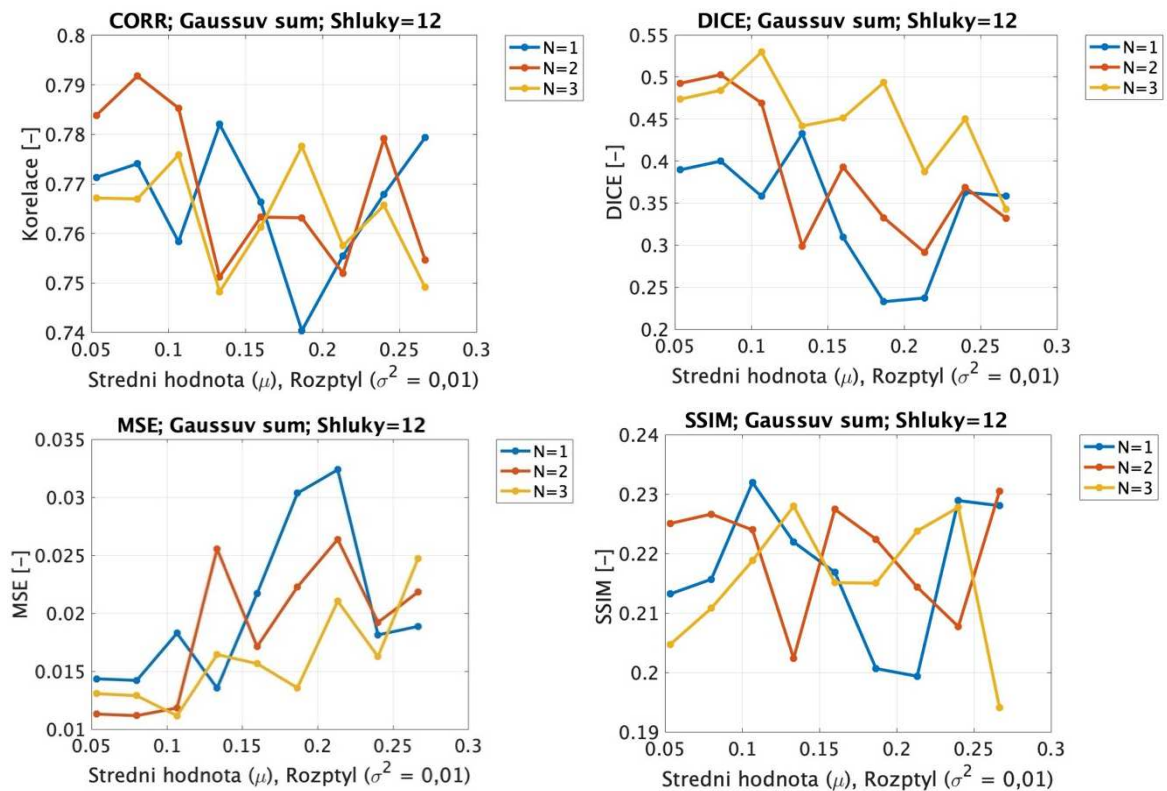
Obr. 65: Závislost fitness funkce na počtu generací pro nastavení populace a generace 20 [vlastní]

Na Obr. 65 je viditelný graf závislosti fitness funkce na počtu generací. Konkrétně v tomto případě byla nastavena generace na hodnotu 20 a populace také na hodnotu 20, následně bylo sledováno, zda dojde k rapidnímu zlepšení ve srovnání s následujícím grafem, kde počet generací zůstává stejný, ale populace je zvýšena na hodnotu 100.



Obr. 66: Závislost fitness funkce na počtu generací pro nastavení populace 100 a generace 20 [vlastní]

Můžeme pozorovat, že na Obr. 66 dochází k mírnému snížení hodnoty fitness funkce při vyšším nastavení počtu populace. Jedna se však o minimální rozdíly, které se však rapidně projeví na výpočetním času metody GA.



Obr. 67: Analýza robustnosti snímků CT cév dle dodatečného nastavení pro Gaussův šum, 12 shluků, 50 populace a metody KM, FCM a GA [vlastní]

Dodatečné nastavení robustní analýzy se skládá ze tří možností, hlavním rozdílem je mezi nimi počet generací, který je v počtech 10 pro nastavení 1, 20 pro nastavení 2 a 40 pro nastavení 3. Elitní počet a frakce křížení byly nastavovány vzhledem k počáteční populaci, poslední z parametrů dodatečného nastavení je výběr selekce.

Na Obr. 67 jsou ve čtyřech grafech vyobrazeny komparace dodatečných nastavení pro jednotlivé evaluační parametry v závislosti na Gaussově šumu. Již pouhým pohledem je patrné, že všechny grafy vykazují nahodilé hodnoty.

Jako neoptimálnější nastavení se v tomto případě jeví nastavení 3, které vykazuje lepší hodnoty u parametrů DICE a MSE. U SSIM a CORR výsledky nastavení mezi sebou nevykazují signifikantní odlišnost.

Nastavení 3 se v tomto případě jeví jako nejlepší volba, naopak nastavení 1 vykazuje nejhorší výsledky. Důležité je však podotknout, že rozdíly dílčích nastavení na základě evaluačních parametrů jsou v pouze v malé míře.

Tabulka 6: Výsledky hodnot evaluačních parametrů pro dataset 1 a Gaussův šum [vlastní]

Průměrné hodnoty evaluačních parametrů pro dataset 1 a Gaussův šum						
Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
GA	3	0.7300	0.7766	0.6423	0.2322	0.0165
	5	0.7600	0.5019	0.3589	0.2428	0.0131
	7	0.7800	0.5362	0.3897	0.2679	0.0151
	10	0.7800	0.5593	0.4114	0.2898	0.0130
	12	0.7900	0.4517	0.3230	0.3021	0.0159
FCM	3	0.7300	0.6266	0.5283	0.1602	0.2699
	5	0.8100	0.6592	0.5503	0.1771	0.3781
	7	0.8300	0.4205	0.3372	0.1912	0.9469
	10	0.8500	0.4254	0.3415	0.1996	1.6206
	12	0.8600	0.3564	0.2862	0.2022	2.1645
KM	3	0.7200	0.7530	0.7554	0.1609	0.1763
	5	0.7900	0.6268	0.5179	0.1774	0.4866
	7	0.7900	0.3005	0.2303	0.1903	1.5730
	10	0.8100	0.3469	0.2757	0.2006	2.9123
	12	0.8200	0.2648	0.1987	0.2092	2.4504

Výše zmíněná Tabulka 6 odkazuje na výsledné hodnoty evaluačních parametrů, vzhledem k velkému počtu výstupních tabulek a hodnot je jako ukázka uvedena tabulka pro Gaussův šum, zbylé výstupy jsou zobrazeny v přílohách této diplomové práce.

Pro názornou odlišnost byly nejlepší a nejhorší hodnoty barevně označeny, červená barva reprezentuje nejhorší hodnotu daného parametru a zelená hodnotu nejlepší. Pokud se zaměříme na parametr CORR, tak FCM vykazuje nejvyšší hodnotu korelace, naopak KM nejnižší, což odpovídá i robustnosti této metody vůči parazitnímu šumu. U ostatních parametrů je situace podobná, KM vykazuje ve třech dalších parametrech nejhorší hodnoty.


Dle rozdělení pro počty shluků můžeme pozorovat, že se zvyšujícím se počtem dochází u většiny parametrů i k vyšší chybovosti. Primárně je tedy nutné stanovit takový počet shluků, abychom byli schopni segmentovat dílčí oblasti snímku a zároveň nezhoršili výsledek při nastavení vysokého počtu shluků.

Nejlepší výsledky kromě FCM metody u parametru CORR vykazuje GA. Většina hodnot vykazuje nejlepší výsledky, což dokazují i výše zmíněné grafy, které ukazují na robustnost genetických algoritmů vůči konvenčnímu KM a současně metodě FCM.

7.2 Výsledky testování snímků CT jater


Výpočetní tomografie obrazu představuje vyšetření jater získaného v příčných vrstvách. Na vyšetření celých jater je potřeba několik takovýchto vrstev. Velkou výhodou této technologie je skutečnost, že celý sken lze provést v době maximální náplně cév kontrastní látkou, čímž se zlepšuje detekce nádorových ložisek a rozlišení drobných cév.

Na Obr. 68 můžeme pozorovat nativní a zašuměný snímek jater. Snímek ovlivněný Gaussovým šumem se částečně jeví jako homogenní struktura, to klade důraz na kvalitu segmentačních technik, které by měly v tomto případě důkladně oddělit dílčí části snímku od parazitního šumu a pozadí.



Obr. 68: Ukázka snímku CT jater. Zleva nativní snímek; zašuměný snímek Gaussovým šumem o intenzitě $\mu=0,15$, $\sigma^2=0,01$ [vlastní]

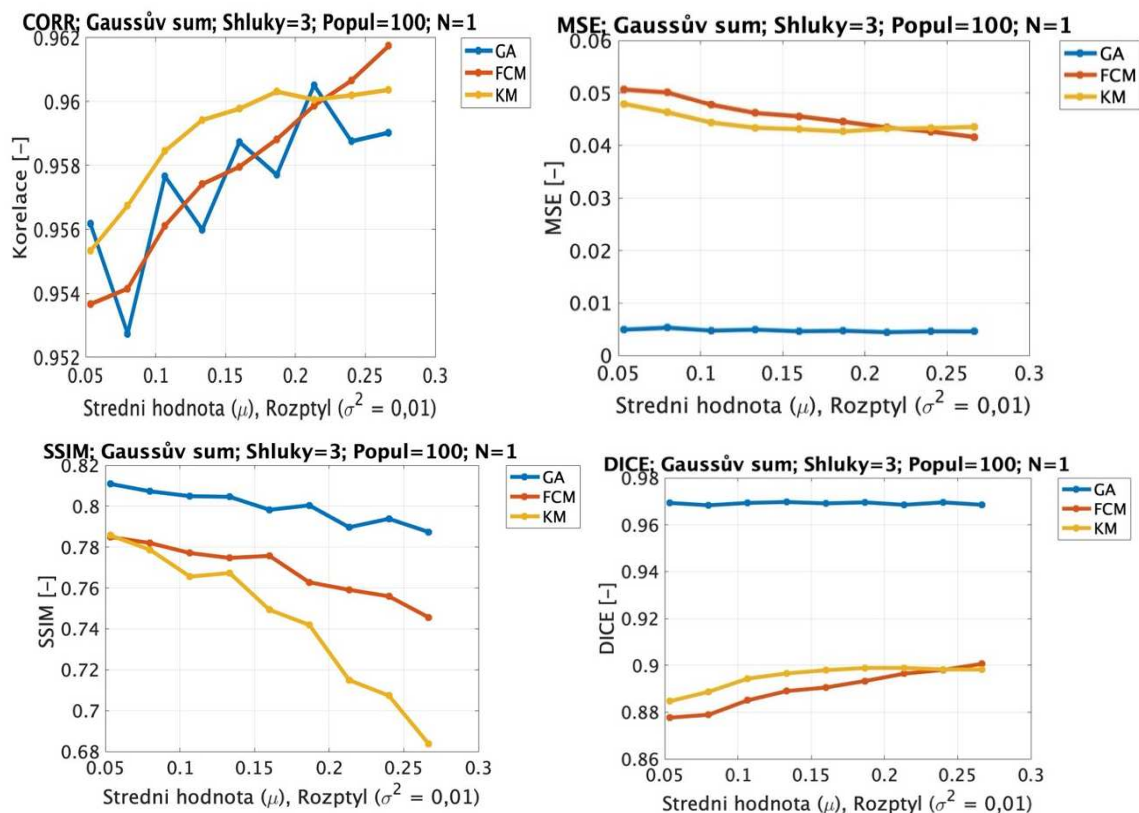
Na Obr. 69 jsou ukázky již segmentovaných snímků. Jedná se o metodu KM, FCM a GA, avšak jednotlivé segmentace působí duplicitně. V tomto případě, kdy dochází k zašumění pouze hodnotami okolo $d=0,15$, nedochází k degradaci obrazových pixelů, tudíž i konvenční metoda KM vykazuje značně kvalitní segmentaci.




Obr. 69: Ukázka snímků pro Gaussův šum o intenzitě $\mu=0,15$, $\sigma^2=0,01$. Zleva metoda KM; FCM; GA [vlastní]

Na Obr. 70 jsou stejně jako u předchozího datasetu ukázány výsledky analýz vytvořených na základě hodnot evaluačních parametrů. CORR v rámci tohoto datasetu vykazuje nejlepší hodnoty pro metodu KM, což je značně zajímavé, neboť pro ostatní parametry je výsledek zcela opačný.

Důvodem může být princip výpočtu korelačního koeficientu, kde při průměrování jasových intenzit pixelů nedochází k odhalení chybovosti jako u ostatních parametrů. Ostatní parametry však jasně vyhodnocují robustnost genetického algoritmu.



Obr. 70: Analýza robustnosti snímků CT jater pro Gaussův šum, 3 shluky a metody KM, FCM a GA [vlastní]



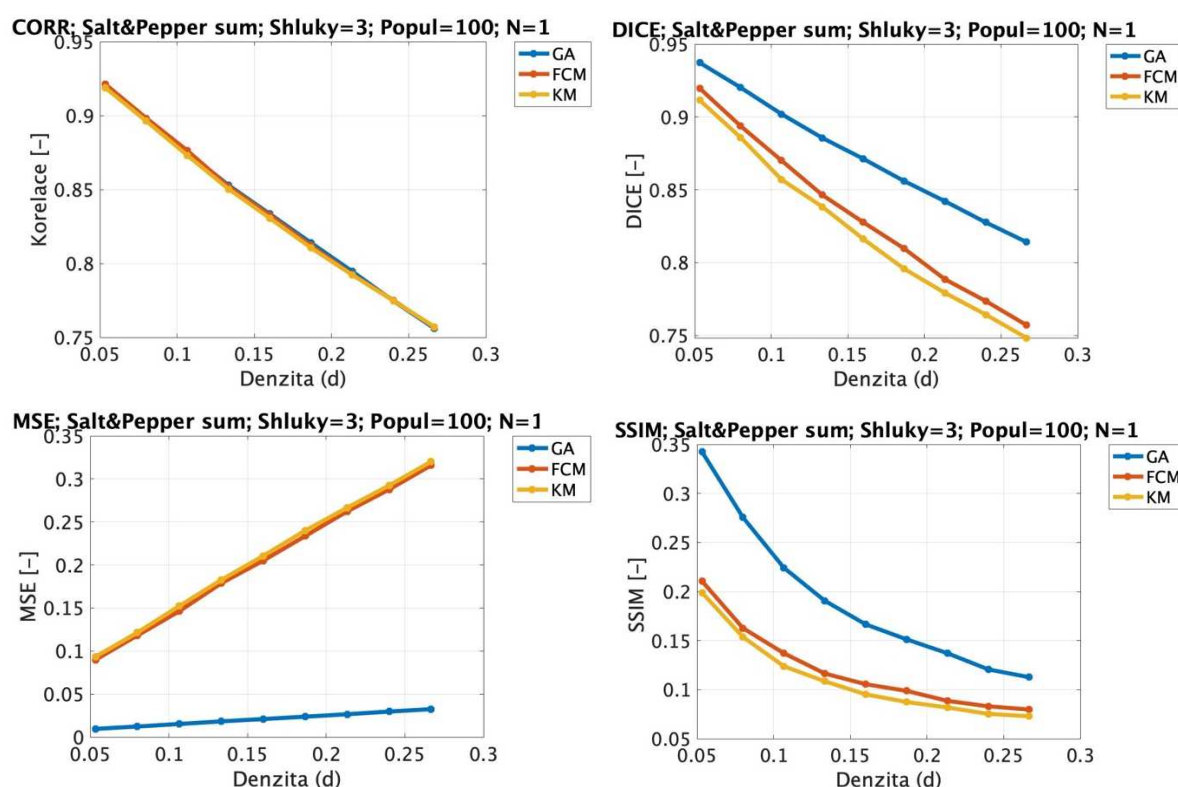
Obr. 71: Ukázka selekce obratle ze snímku CT jater ovlivněného šumem. Zleva nativní snímek; zašuměný snímek Gaussovým šumem $\mu=0,1$, $\sigma^2=0,01$; segmentovaný snímek metodou GA pro 3 shluky [vlastní]

Výsledná segmentace nemusí být zaměřena pouze na obraz jako celek, ale je možné selektovat určitou oblast zájmu a zaměřit se na její detaily. V tomto případě segmentace obratle jasně ukazuje robustnost genetického algoritmu, který při nastavení 3 shluků s přesností ohraničil obratel (shluk žluté barvy).

Stejným způsobem je možné selektovat například nádory a následně změřit jejich velikost či u volumetrické segmentace i objem, který je velmi důležitý pro následné plánování léčebných a terapeutických postupů.

Níže vyobrazené grafy, viz Obr. 72, reprezentují výsledky pro Salt&pepper šum a 3 shluky. Tento počet shluků je vzhledem k variabilitě snímků jater velmi malý a metoda není schopna přesně segmentovat všechny důležité orgány. Výsledky jasně ukazují znovu na genetický algoritmus, který při nastavení populace 100 a dodatečným nastavením 1 vykazuje nejlepší hodnoty u parametrů MSE, DICE a SSIM.

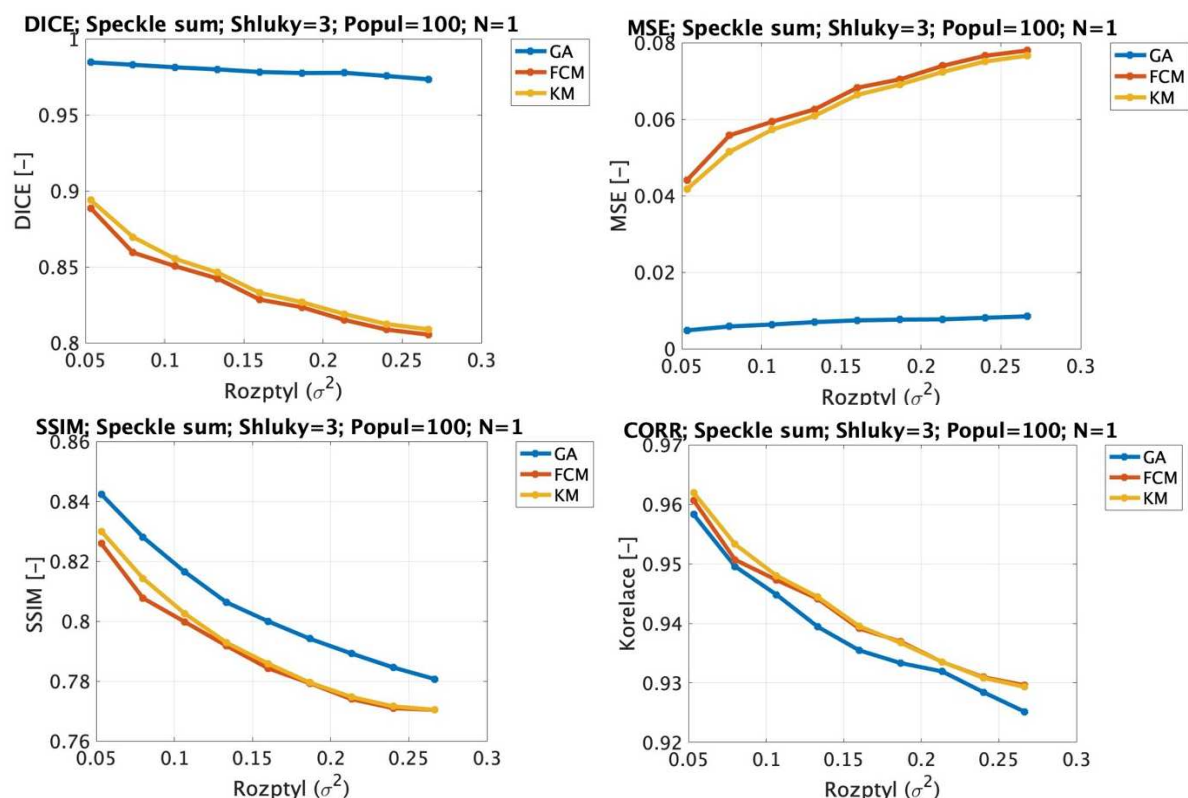
Korelace u všech metod vykazuje stejné výsledky a jednotlivé křivky korelují mezi sebou. Metoda FCM a KM ve většině případů dosahuje duplicitních výsledků s mírnou odlišností u parametrů SSIM a DICE, kde FCM dosahuje lepších výsledků.



Obr. 72: Analýza robustnosti snímků CT jater pro šum Salt&pepper, 3 shluky a metody KM,FCM a GA [vlastní]

Z následující analýzy na Obr. 72 dostáváme nejlepší hodnoty znovu u GA, avšak parametr korelace opět vyhodnotil GA jako nejhorší, hodnoty se zde ale od sebe liší jen v rámci desetín. Ostatní metody KM a FCM jako u předchozích grafů dosahují podobných hodnot.


DICE koeficient pro nastavení 3 shluků a Speckle šum jasně ukazuje na výkonnost genetického algoritmu, který dosahuje hodnot blízkých se 1, kdežto metoda FCM a KM se zvyšující se intenzitou šumu nabývá klesajících hodnot. Stejný úkaz můžeme pozorovat i u parametru MSE, kde dochází ke zvyšující se chybovosti, tudíž i křivka nabývá stoupajících hodnot v závislosti na intenzitě šumu.



Obr. 73: Analýza robustnosti snímků CT jater pro šum Speckle, 3 shluky a metody KM, FCM a GA [vlastní]


Jak již bylo zmíněno u CT snímků jater, důležitým parametrem je právě počet shluků, neboť je obraz složen z mnoha tkání, které vykazují odlišné jasové parametry. Následná analýza na Obr. 74 nám dává jasný přehled o volbě počtu shluků.

Nejlepší hodnoty SSIM a CORR parametru dosahují nastavení pro 10 a 12 shluků. To je dáno právě tím, že segmentace přesně dokáže separovat jednotlivé tkáně, kdežto při nastavení 3 shluků je výsledek každé segmentace odlišný. Pokud tedy analyzujeme snímky s velkou jasovou variabilitou, je nutné volit i vyšší počet shluků.




Obr. 74: Analýza robustnosti snímků CT jater dle počtu shluků, pro Salt&pepper šum a metodu KM [vlastní]

Pro Salt&pepper šum a metodu GA vykazují níže zobrazené grafy na Obr. 75 podobné výsledky jako na Obr. 74. Je vidět, že metoda GA vykazuje kvalitnější řešení pro vyšší počet shluků, tedy konkrétně pro 12. Je to zapříčiněno tím, že jak již bylo zmíněno, CT snímky jater vykazují vyšší jasovou variabilitu a metoda GA je schopna jednotlivé segmenty lépe rozlišit a rozčlenit než výše interpretovaná metoda KM.




Obr. 75: Analýza robustnosti snímků CT jater dle počtu shluků, pro Salt&pepper šum a metodu GA [vlastní]



Obr. 76: Srovnání nastavení počtu shluků pro metodu GA a Gaussův šum o intenzitě $\mu=0,1$, $\sigma^2=0,01$. Zleva nastavení pro 3; 5; 7; 10 shluků [vlastní]

Dodatečné nastavení GA je složeno z počtu generací, což byl jeden z hlavních sledovaných parametrů, součástí je i frakce křížení s konstantním nastavením 0,5, typ selekce a elitní počet, který je volený v závislosti na počtu shluků.

Výsledky na Obr. 77 ukazují dle parametru DICE na nastavení 2, které dosahuje v jisté míře lepších hodnot, a to hlavně v závěru, kdy je intenzita šumu nejvyšší.



Obr. 77: Analýza robustnosti snímků CT jater dle dodatečného nastavení pro Salt&pepper šum, 10 shluků, 150 populace a metody KM,FCM a GA [vlastní]

Níže zmíněná Tabulka 7 odkazuje na výsledné hodnoty evaluačních parametrů, vzhledem k velkému počtu výstupních tabulek a hodnot je jako ukázka uvedena tabulka pro Salt&pepper šum, zbylé výstupy jsou zobrazeny v přílohách této diplomové práce. Zelená barva opět označuje nejlepší hodnoty jednotlivých parametrů, červená naopak hodnoty nejhorší.

Již na první pohled je jasné, že GA dosahuje nejlepších hodnot u čtyř z pěti parametrů. Jediná hodnota je odlišná u parametru CORR, kde dosahuje metoda FCM lepší korelace. S jistotou tedy můžeme říct, že GA vykazuje mnohem lepší výsledky, a to v kontextu všech typů šumů, což dokazují i výše zmíněné grafické zobrazení.


Tabulka 7: Výsledky hodnot evaluačních parametrů pro dataset 3 a Salt&pepper šum [vlastní]

Průměrné hodnoty evaluačních parametrů pro dataset 3 a Salt&pepper šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Salt&pepper	GA	3	0.8518	0.8856	0.7990	0.2721	0.0188
		5	0.8643	0.8766	0.7864	0.2904	0.0113
		7	0.8716	0.8919	0.8092	0.3105	0.0099
		10	0.8736	0.8528	0.7493	0.3165	0.0091
		12	0.8776	0.8941	0.8123	0.3322	0.0082
	FCM	3	0.8517	0.8487	0.7540	0.2082	0.1838
		5	0.8721	0.7935	0.6817	0.2042	0.4034
		7	0.8739	0.7184	0.5979	0.2036	0.7873
		10	0.8872	0.7286	0.6026	0.2142	1.3475
		12	0.8765	0.7262	0.6005	0.2128	2.3419
	KM	3	0.8504	0.8397	0.7424	0.1997	0.1879
		5	0.8708	0.7788	0.6630	0.1971	0.4249
		7	0.8792	0.7531	0.6317	0.2161	0.8190
		10	0.8865	0.7012	0.5704	0.2088	1.3422
		12	0.8845	0.2295	0.2000	0.2080	2.1383

7.3 Výsledky testování datasetu MRI chrupavky

Vzhledem k velmi vysokému počtu grafických výstupů je dataset MRI chrupavky a poté i následující dataset v kapitole 7.4 zhodnocen pouze slovně. Všechny grafické a tabulkové výstupy jsou uloženy v přílohách této diplomové práce.

Na Obr. 78 je ukázka segmentovaných snímků datasetu MRI chrupavky kolene metodou GA pro tři nastavení počtu shluků. Stejně jako i u přechozích snímků jsme schopni stanovit, že optimálním počtem shluků se v tomto případě jeví 7 či 10 shluků. Nastavení pro 3 shluky bohužel není přesně schopno detekovat oblasti chrupavky kolene. Chrupavka kolene nevykazuje takovou jasovou variabilitu jako například předchozí snímky CT jater, tudíž je vhodné volit menší počet shluků pro rozdělení na separátní segmenty.




Obr. 78: Ukázka snímku MRI chrupavky. Zleva zašuměný snímek Gaussovým šumem $\mu=0,2$, $\sigma^2=0,01$; segmentované snímky metodou FCM pro 3; 5; 7 shluků [vlastní]

Pokud se zaměříme na grafické zhodnocení tohoto datasetu, tak pro všechny typy šumů opět dosahuje nejlepších hodnot metoda GA. V rámci komparace jednotlivých metod vykazují parametry podobné výsledky jako u výše zmíněných datasetů. Parametr CORR částečně dle některých grafů vykazuje jako úspěšnější metodu KM, avšak všechny ostatní parametry ukazují pravý opak. SSIM ve většině výsledků vykazuje vyšší úspěšnost GA nad KM a FCM, a to zhruba o 20 %. DICE a JACCARD koeficient vzhledem ke svému podobnému algoritmu výpočtu dosahují téměř duplicitních hodnot. Výsledky dosahují pro analýzu snímků ovlivněných Gaussovým šumem a segmentovaných metodou GA velmi uspokojivých hodnot konstantního průběhu blíží se k 90 % původní segmentace. To značí velmi úspěšnou segmentaci, neboť metoda KM v tomto případě dosahuje pouze hodnoty 30 %, a pokud porovnáme i FCM, která disponuje fuzzy logikou, zde je hodnota blíží se 40 %. Pro parametr MSE, který porovnává jednotlivé pixely evaluovaných snímků dosahuje vysoké chybovosti opět pro metodu KM a FCM, kde grafické zobrazení vykazuje téměř lineární průběh. Na druhou stranu GA se ukazuje jako nejefektivnější a závislost chybovosti na základě MSE je v tomto případě téměř lineární, což jen potvrzuje robustnost GA vůči parazitnímu šumu.

Další analýzy zaměřené na volbu počtu shluků vykazuje u snímků ovlivněných Gaussovým šumem nejlepších hodnot pro nastavení 3 shluků. Zajímavé v tomto případě je, že pokud změním šum na Salt&pepper, je nejlepší volbou vyšší počet shluků 7 a 10. Nastavení vhodné populace v tomto případě vychází stejně jako u předchozího datasetu, tedy 20. Dodatečné nastavení vykazuje v nižších hodnotách šumu podobné výsledky s menší převahou nastavení 1. Při zvýšení intenzity šumu však je již nastavení 1 vyhodnoceno jako nedostačující, a to kvůli nízkému počtu generací a převažuje nastavení 2 a 3.

7.4 Výsledky testování datasetu MRI cév

Následující výsledky byly vyhodnoceny na snímcích pocházejících z MRI cév. Jednotlivá zobrazení můžeme pozorovat na Obr. 79, kde je snímek zobrazující ledviny spolu s cévním zásobením abdominální oblasti a dolních končetin. Snímky reprezentují odlišná nastavení shluků, kde již pouhým okem můžeme stanovit, že nejlepších výsledků dosahují snímky pro 5 a 7 shluků, avšak snímek pro 3 shluky v tomto případě vykazuje také kvalitní segmentaci.



Obr. 79: Ukázka snímku MRI cév. Zleva zašuměný snímek Gaussovým šumem $\mu=0,1$, $\sigma^2=0,01$; segmentované snímky metodou GA pro 3; 5; 7 shluků [vlastní]

Grafické analýzy a zhodnocení tohoto datasetu jsou obsaženy v přílohách této práce. Pokud bychom se měli zaměřit na komplexní diferenciaci metod, opět zde vítězí metoda GA, která díky prvkům genetiky dokáže nejlépe segmentovat zašuměné snímky. Tyto výsledky dokazují i hodnoty, které pro Speckle šum dosahují o 15 % lepších výsledků než metoda FCM a ve srovnání s konvenčním KM dokonce o 20 %. Parametr korelace pro GA ve všech případech šumu vykazuje oproti FCM a KM pouze mírně lepší hodnoty, a to zhruba o 5 %. Při ovlivnění šumem Salt&pepper vykazuje střední kvadratická chyba velmi rozdílných hodnot, GA se v tomto případě s konstantním průběhem křivky blíží k nulové chybovosti, kdežto FCM dosahuje až o 30 % horší úspěšnosti, KM poté až o 40 %.

Pokud se zaměříme na další z výsledných analýz jako je vhodný počet shluků, tak u tohoto datasetu vzhledem k jasovým intenzitám snímků MRI cév vyšel nejlepší počet 5 a 7 shluků. V rámci šumu Salt&pepper byly vyhodnoceny jako lepší nastavení počet 7 a 10 shluků, což bylo s největší pravděpodobností zapříčiněno zkreslením přidaného impulsního šumu.


V kontextu volby populace u GA byly výsledky vyhodnoceny téměř duplicitně jako u předchozích datasetů. Nedochozí zde k rapidnímu zlepšení segmentace v kontextu zvýšení počáteční populace, naopak se velmi prodlužuje výpočetní čas, který je při včasné diagnostice tkání nežádoucí.

Dodatečné nastavení vychází jako nejlepší volba pro nastavení 2, což je zlatý standard, neboť generace je na úrovni 20, zvolení elitního počtu je 5 a selekce je stochastická. Toto nastavení již vyšlo jako nejlepší i v předchozích analýzách ostatních datasetů. Důležité je však zmínit, že výsledná křivka pro dodatečné nastavení nabývá skokových hodnot a jednotlivé výstupy se liší pouze v jednotkách procent. V níže zmíněných zhodnoceních bylo zjištěno, že snímky MRI cév vykazují nejvyšší odolnost vůči Speckle šumu, nejnižší naopak vůči Gaussově šumu.

7.5 Extrakce a modelování tkání metodami shlukové analýzy

Radiodiagnostické metody jsou často využívány se záměrem získání kvalitního obrazového výstupu určité oblasti zájmu lidské tkáně. Pokud je tkáň špatně viditelná nebo nerozeznatelná od pozadí, jsou využívány kontrastní látky, které zapříčiní, že vyšetřovaná tkáň se na snímcích projeví jako oblast s vyšší jasovou intenzitou. Lékař tedy dokáže s vysokou přesností identifikovat kalcifikace cév, nádory, cysty či jiné patologie. Pokud bychom se chtěli více zaměřit na výslednou oblast zájmu, přichází na řadu modelování tkání, což je proces, při kterém jsme schopni kompletně odstranit objekty obrazu, které považujeme za nezajímavé. Výsledkem je binární obraz s konečnou oblastí zájmů, kterou je možné dodatečně analyzovat či spočítat její plochu.

Principem modelování tkání z obrazových dat je v první řadě segmentační algoritmus, který zajistí kvalitní a odolnou segmentaci vůči šumu. Součástí výstupu je segmentační mapa reprezentovaná jednotlivými segmentačními třídami, kde každé z nich je přidělen unikátní index. Díky číselnému indexu je možné danou třídu v obraze identifikovat a následně odfiltrovat. Pokud zachováme pouze důležité segmentační třídy s oblastí zájmu, zbylé třídy jsou nastaveny na požadovanou hodnotu barevného spektra, tudíž se jejich pixely zobrazí jako oblast s bílou barvou.



Obr. 80: Ukázka segmentovaných snímků metodou PSO pro extrakci oblasti zájmu [vlastní]

Testování bylo provedeno na třech snímcích segmentovaných pomocí metod KM, FCM, GA a PSO, jednotlivé snímky můžeme vidět na Obr. 80. Počet shluků byl v tomto případě nastaven na hodnotu 3, a to z důvodu následné extrakce jednotlivých tkání. Všechny snímky byly systematicky ovlivněny parazitními šумы, které jsou popsány v kapitole č. 5. Nastavení jednotlivých šumů bylo realizováno pro pět intenzit, rozsah intenzit je popsán v kapitole 5, kde pro extrakci tkání byla maximální hodnota šumu stanovena na 0,35.

Následně byla pomocí indexu jednotlivých segmentačních tříd odfiltrována důležitá oblast zájmu, v našem případě cévní řečiště hlavy, krku a pánve. Na Obr. 81 můžeme pozorovat již jednotlivé tkáně extrahované z původních snímků. Snímek vlevo byl vybrán záměrně, neboť zobrazuje pouze části cév, které jsou již postiženy kalcifikací, ostatní snímky uprostřed a vpravo zobrazují celkové cévní řečiště dané oblasti.




Obr. 81: Extrakce a modelování tkání, vlevo kalcifikace cév, uprostřed cévní řečiště hlavy a krku, vpravo cévní řečiště cév oblasti pánve [vlastní]


7.5.1 Výstupy extrakce pro Gaussův šum

Demonstrativní snímky vyobrazené na Obr. 82 ukazují tři intenzity Gaussova šumu. Segmentace oblasti zájmu byla provedena za pomoci konvenční metody KM. Výsledky by tedy měly vykazovat v porovnání s ostatními metodami na bázi umělé inteligence nižší kvalitu. V počátečních hodnotách nastavení aditivního šumu je ovlivnění výsledných obrazů minimální, avšak okolo hodnoty $\sigma^2=0,01$, $\mu=0,35$ dochází k rapidnímu zhoršení a pouhým okem je problémem oddělení cévního řečiště od šumu.



Obr. 82: Ukázka výstupu extrakce pro Gaussův šum a metodu KM. Zleva nastavení: $\sigma^2=0,01$, $\mu=0,1$; $\sigma^2=0,01$, $\mu=0,2$; $\sigma^2=0,01$, $\mu=0,35$ [vlastní]






Obr. 83: Analýza robustnosti extrahovaných snímků pro Gaussův šum [vlastní]

Grafická zhodnocení vykazují velmi rozdílné trendy v kontextu metody KM a metod využívající umělé inteligence, tedy GA, FCM a PSO. Je jasně patrné, že metoda KM je při vyšších intenzitách aditivního šumu nedostačující. Gaussův šum v případě aplikace na extrahované cévní řečiště razantně ovlivňuje obrazové pixely, což je viditelné na Obr. 82 pro nastavení $\sigma^2=0,01$, $\mu=0,35$. Pokud se zaměříme na komparaci metod umělé inteligence, můžeme dle analýzy na Obr. 83 pozorovat mírnou převahu metody GA nad PSO. FCM v tomto v případě u parametrů SSIM, MSE a CORR, vykazuje strmější trend. Metoda PSO se v kontextu ovlivnění Gaussovým šumem jeví jako druhá nejlepší po GA.

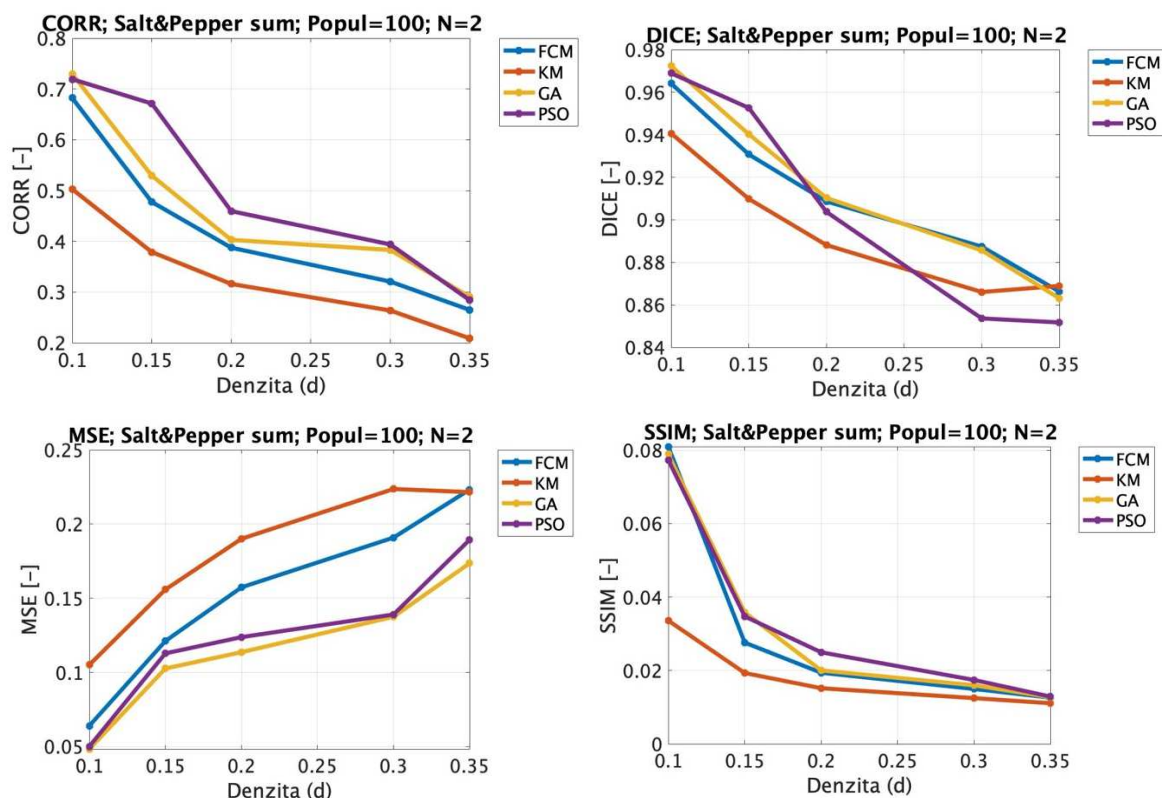
7.5.2 Výstupy extrakce pro Salt&pepper šum

Šum Salt&pepper se projevuje náhlými změnami v obraze, kde dochází k tvorbě černých nebo bílých pixelů, jedná se o velmi agresivní šum, neboť při vyšších intenzitách dochází ke sjednocení sledované oblasti zájmu spolu s pozadím snímku. Na Obr. 84 je zřetelně vidět, že při nízkých hodnotách šumu $d=0,1$ je dobře viditelné cévní řečiště spolu s částmi obou ledvin.

V případě nejvyššího nastavení šumu Salt&pepper $d=0,35$ již zvolna dochází k zániku jedné z ledvin a druhá je téměř nečitelná. Ve většině případů je tento šum dobře eliminován mediánovým filtrem, avšak i přes filtraci často dochází ke zhoršení výsledné segmentace.



Obr. 84: Ukázka výstupu extrakce pro Salt&pepper šum a metodu PSO. Zleva nastavení: $d=0,1$; $d=0,2$; $d=0,35$ [vlastní]




Obr. 85: Analýza robustnosti extrahovaných snímků pro Salt&pepper šum [vlastní]

Nejodolnější metoda vůči šumu je dle výsledné analýzy na Obr. 85 v tomto případě znovu PSO spolu s GA. Metoda PSO dosahuje v parametru CORR a SSIM nejlepších výsledků, trend GA je téměř totožný s PSO. Modrá křivka reprezentující metodu FCM vykazuje vcelku průměrný trend vzhledem k ostatním metodám. Nejhorší volbou se v tomto případě opět jeví metoda KM, dle parametru MSE a CORR je trend jasně čitelný. U parametrů DICE a SSIM dochází při vyšších intenzitách šumu k ustálení křivky, kde v hodnotě šumu $d=0,35$ se dokonce rovná či u DICE parametru i převyšuje ostatní metody.

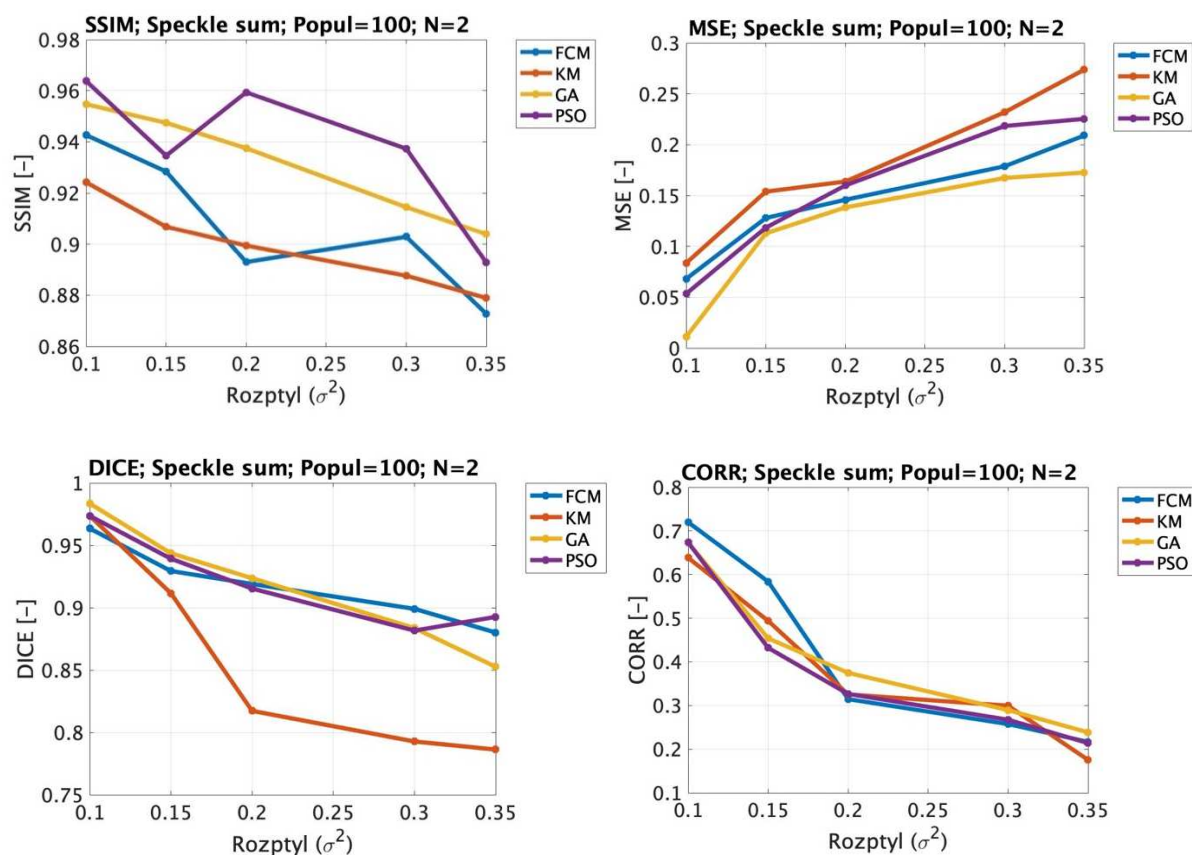
7.5.3 Výstupy extrakce pro Speckle šum

Tento typ šumu se nejčastěji vyskytuje u zobrazovacích metod, kde dochází k interferencím snímaných signálů, takovým případem můžou být ultrazvukové přístroje. Speckle šum ovlivňuje především pixely s vyšší jasovou intenzitou, nejčastěji tedy snímané oblasti zájmu, kde se zvyšující se intenzitou se rapidně snižuje přehlednost vyšetřované oblasti, viz Obr. 86. Na obrázku můžeme pozorovat cévní řečiště oblasti hrudníku, kde byla pro názornou ukázkou ponechána segmentační třída kalcifikace, která je vyobrazena pixely černé barvy. Při intenzitě okolo $d=0,1$ je kalcifikace vcelku dobře viditelná, avšak již při intenzitě šumu $d=0,2$ na obrázku uprostřed dochází ke zkreslení detailů a zániku kalcifikace do pozadí.



Obr. 86: Ukázka výstupu extrakce pro Speckle šum a metodu PSO. Zleva nastavení: $\sigma^2=0,1$; $\sigma^2=0,2$; $\sigma^2=0,35$ [vlastní]


Grafické výstupy parametrů dle Obr. 87 ukazují výsledky pro segmentovaný snímek kalcifikované cévy s následnou extrakcí. Zvolen byl Speckle šum o třech intenzitách. Průměrné hodnoty metody KM v grafech parametrů CORR a MSE dosahují poměrně stejných hodnot jako PSO či GA. Horší výsledek je viditelný u parametru DICE, který ukazuje na nižší kvalitu segmentovaných oblastí u metody KM. SSIM metody KM koreluje s metodou FCM. PSO a GA dosahují společně hladkých trendů kromě parametru SSIM, kde okolo hodnoty šumu $\sigma^2=0,2$ dochází k prudké změně zapříčiněné s největší pravděpodobností vyšší senzitivitou vůči šumu.



Obr. 87: Analýza robustnosti extrahovaných snímků pro Speckle šum [vlastní]

Součástí testování extrakce tkání byla i metoda PSO založená na principu chování roje částic. Na níže dvou uvedených grafech, viz Obr. 88 je možnost porovnat závislost hodnot fitness funkce u metody PSO a u metody GA, která pracuje na principu genetiky.


Je patrná rozdílnost v průběhu jednotlivých grafů, stejným jevem je však klesající funkce, což je důkazem, že s každou další iterací/generací dochází k minimalizaci rozptylu uvnitř shluku. U GA dochází již po zhruba 5 generacích k ustálení křivky a hodnoty se v tomto případě mění jen s minimální mírou. U PSO můžeme pozorovat, že k ustálení dochází přibližně až na hodnotě iterace 20. Předešlé výsledky však jasně ukazují, že minimalizace rozptylu u obou metod je velmi efektivní, neboť oproti konvenční metodě KM dosahují mnohem lepších výsledků.



Obr. 88: Graf závislosti fitness hodnoty na počtu generace u metody PSO (vlevo) a GA (vpravo) s nastavením populace 100 a generace/iterace 20 [vlastní]

7.6 Komplexní zhodnocení metod


V předchozích kapitolách byly analýzy zaměřeny pouze na výsledky parametrů pro jednotlivé datasety. Níže zmíněné grafy popisují průměr evaluačních hodnot všech 40 snímků, všech typů šumů, a to za účelem komplexního pohledu na danou problematiku. Pro ukázkou zde budou popsány jen některé z výsledných parametrů, ostatní grafická zhodnocení budou uložena v přílohách.



Obr. 89: Analýza robustnosti datasetů pro Gaussův šum, všechny metody a 10 shluků [vlastní]

Pokud bychom chtěli zjistit, který typ šumu je schopen nejvíce degradovat medicínské snímky v závislosti na jejich původu, jsou vhodným ukazatelem výše zmíněné grafy na Obr. 89. Srovnání zde bylo realizováno pro průměr hodnot všech hodnot parametru CORR a SSIM.

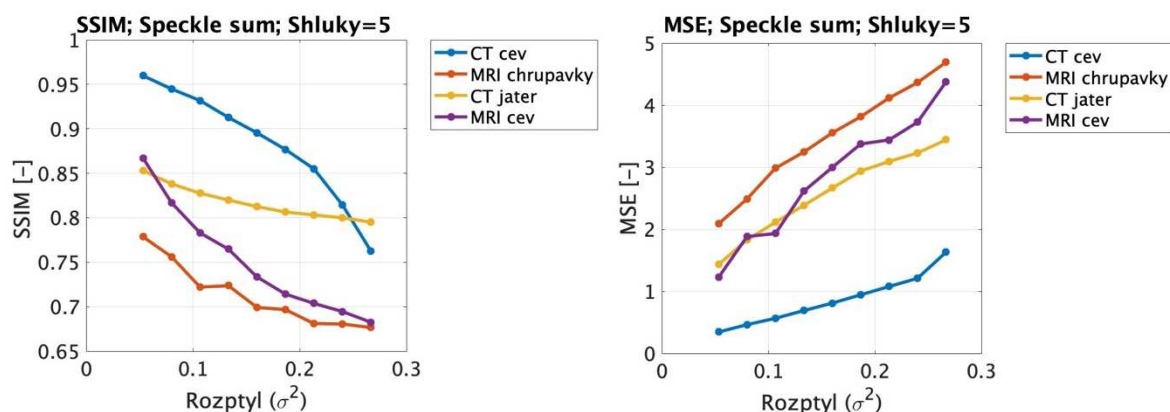
Pro oba grafy je jasné viditelné, že nejvíce byly šumem ovlivněny snímky CT cév a MRI cév. Nejlepší hodnoty naopak vykazuje dataset MRI chrupavky. Částečně můžou být jednotlivé výsledky ovlivněny i vstupním rozlišením snímků, které bylo rozdílné.



Obr. 90: Analýza robustnosti jednotlivých datasetů v kontextu Salt&pepper šumu pro všechny metody a 7 shluků [vlastní]

Pro nastavení 7 shluků a stejný typ šumu Salt&pepper jsou výsledky na Obr. 90 téměř duplicitní jako na předchozích grafech pro nastavení 10 shluků. Rozdíl můžeme vidět pouze u datasetu MRI cév, který pro parametr CORR nabývá nejhorších hodnot, kdežto pro SSIM je nejhorší dataset CT cév.


Poslední vyhodnocení pro zjištění, který z datasetů vykazuje nejnižší odolnost vůči parazitnímu šumu, je analýza na základě parametrů SSIM a MSE pro 5 shluků a Speckle šum na Obr. 91. Jak již bylo zmíněno, Speckle šum ovlivňuje především zobrazovanou oblast, nejčastěji tkáň či cévy. Výsledky u obou parametrů ukazují, že jsou nejméně odolné snímky MRI chrupavky. Nejlepší výsledky naopak vykazují snímky CT cév.



Obr. 91: Analýza robustnosti jednotlivých datasetů v kontextu Speckle šumu pro všechny metody a 5 shluků [vlastní]

Následující grafy byly vyhotoveny na základě průměru ze všech 40 snímků a jednotlivé typy šumu. Na prvních dvou grafech, viz Obr. 92 můžeme vidět výsledky parametru DICE a SSIM pro Gaussův šum a nastavení 7 shluků.

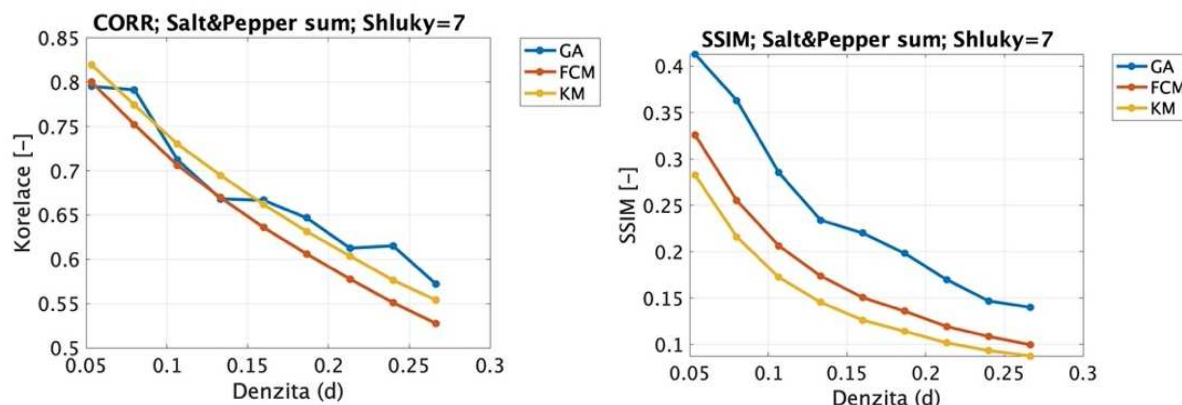
Jasným výsledkem analýzy je metoda GA, která dosahuje nejvyšších hodnot u obou parametrů. Metoda FCM vykazuje rapidně horší výsledky, avšak stále je efektivnější než metoda KM. V případě Gaussova šumu je tedy nejrobustnější metoda GA.



Obr. 92: Analýza robustnosti jednotlivých metod v kontextu Gaussova šumu pro všechny datasety a 7 shluků [vlastní]

Pokud se podíváme na celkovou analýzu pro Salt&pepper šum a 7 shluků, viz. Obr. 93 je jasným důkazem, že metoda GA nabývá kvalitnější segmentace než metody KM a FCM. U grafu parametru CORR je znatelné, že GA v počátku mírně dosahuje nižší korelace než KM, avšak se zvyšující se intenzitou šumu dochází v závěru u metody GA k větší úspěšnosti, byť jen o jednotky procent.


Na druhou stranu parametr SSIM jasně vyhodnotil GA jako nejrobustnější segmentační metodu, FCM dosahuje nižších hodnot strukturální podobnosti, ale pořadí má lepší průběh než konvenční KM.



Obr. 93: Analýza robustnosti jednotlivých metod v kontextu Salt&pepper šumu pro všechny datasety a 7 shluků [vlastní]

Posledním z grafů je na Obr. 94 analýza na základě ovlivnění snímků Speckle šumem. Parametr CORR zde opět jako u přechodících analýz nedosahuje signifikantního rozdílu GA a ostatních metod. Pro vyšší intenzitu šumu, který ovlivňuje nejčastěji zobrazovanou tkáň, však stále GA vykazuje nejvyšší robustnost.

Parametr JACCARD, který hodnotí kvalitu segmentace vůči zlatému standardu, jasně ukazuje na GA. FCM a KM v tomto případě mezi sebou navzájem korelují a dosahují mnohem nižších hodnot než GA.



Obr. 94: Analýza robustnosti jednotlivých metod v kontextu Speckle šumu pro všechny datasety a 7 shluků [vlastní]

7.7 Výpočetní náročnost metod

Pro zajištění kvalitního výsledku segmentace je důležité zhodnotit výpočetní náročnost jednotlivých metod, abychom byli schopni určit poměr mezi kvalitou a délkou segmentace. Konvenční metoda KM je obecně známa pro svou velmi rychlou, avšak ne vždy přesnou segmentaci, na druhou stranu metody s prvky umělé inteligence disponují přesnějšími segmentačními algoritmy, které jsou však vykoupěny velkou výpočetní náročností. Následující tabulky hodnotí výpočetní náročnost jednotlivých metod. Vzhledem k velkému počtu výstupních dat jsou zde uvedeny výpočty pouze pro dataset CT cév. Veškeré výpočty a testování byly provedeny v softwaru MATLAB pomocí vestavěné funkce.

Tabulka 8: Výpočetní náročnost metod KM a FCM pro všechny typy šumů [vlastní]

Algoritmus	KM					FCM				
	3	5	7	10	12	3	5	7	10	12
Gaussův šum	15,45 s	18,24 s	22,34 s	28,38 s	35,41 s	96,56 s	104,54 s	107,21 s	110,68 s	112,43 s
Salt&pepper šum	15,96 s	16,17 s	19,35 s	20,35 s	32,98 s	97,58 s	100,28 s	100,47 s	101,21 s	102,65 s
Speckle šum	15,22 s	16,40 s	19,73 s	23,41 s	31,32 s	96,82 s	97,06 s	100,15 s	101,45 s	103,27 s

Výše zmíněná Tabulka 8 ukazuje výpočetní čas pro metody KM a FCM rozdělené dle jednotlivých typů šumů. Výsledné časy se postupně při navýšování počtu shluků prodlužují, avšak dosahují maximálně jednotek minut. Nejvyšší časová náročnost je u segmentace, kde byly snímky ovlivněny Gaussovým šumem. Následující Tabulka 9,

Tabulka 10 a

Tabulka 11 je věnována výpočetní náročnosti metody GA. Již na první pohled je jasné, že ve všech nastaveních a typech šumu jsou výsledné časy mnohonásobně vyšší než u konvenční metody KM a FCM. Hlavní parametr, který ovlivňuje výsledný čas, je počáteční populace, zde bylo zjištěno, že mezi nejnižším nastavením 20 a nejvyšším 200 populace je časový nárůst téměř čtyřnásobný.

Tabulka 9: Výpočetní náročnost metody GA s nastavením 1, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]

Algoritmus	GA – Nastavení 1														
Počet shluků	3					7					12				
Populace	20	50	100	150	200	20	50	100	150	200	20	50	100	150	200
Gaussův šum	4 min	9 min	12 min	18 min	21 min	8 min	14 min	20 min	25 min	32 min	11 min	18 min	29 min	33 min	36 min
Salt&pepper šum	4 min	8 min	11 min	13 min	17 min	5 min	11 min	18 min	23 min	30 min	9 min	16 min	24 min	30 min	33 min
Speckle šum	4 min	8 min	11 min	15 min	20 min	8 min	13 min	19 min	24 min	30 min	10 min	17 min	26 min	33 min	34 min

Tabulka 10: Výpočetní náročnost metody GA s nastavením 2, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]

Algoritmus	GA – Nastavení 2														
Počet shluků	3					7					12				
Populace	20	50	100	150	200	20	50	100	150	200	20	50	100	150	200
Gaussův šum	6 min	9 min	14 min	17 min	23 min	9 min	13 min	22 min	29 min	34 min	10 min	16 min	25 min	34 min	39 min
Salt&pepper šum	5 min	9 min	15 min	17 min	23 min	6 min	14 min	21 min	27 min	33 min	12 min	18 min	24 min	35 min	37 min
Speckle šum	5 min	8 min	13 min	19 min	25 min	8 min	13 min	24 min	30 min	35 min	12 min	17 min	26 min	34 min	38 min

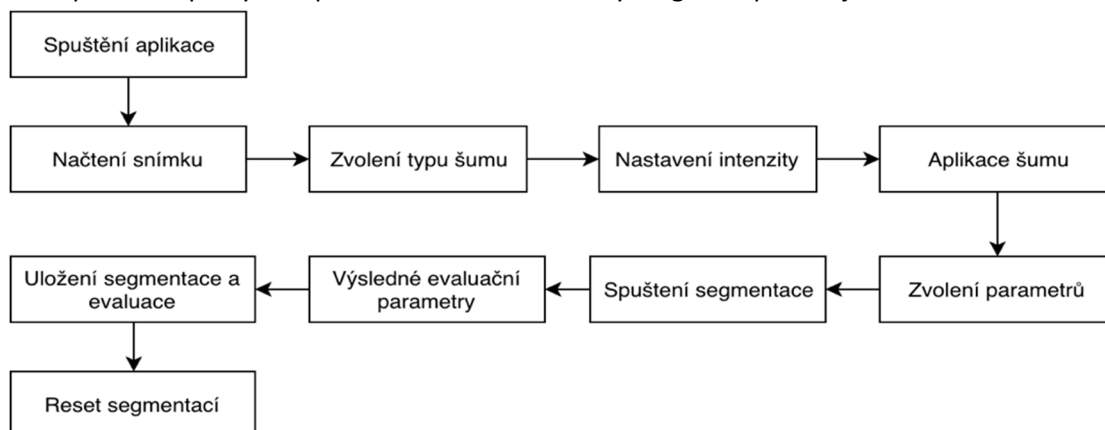
Tabulka 11: Výpočetní náročnost metody GA s nastavením 2, počet shluků 3, 7, 12 a všechny typy šumů [vlastní]

Algoritmus	GA – Nastavení 3														
Počet shluků	3					7					12				
Populace	20	50	100	150	200	20	50	100	150	200	20	50	100	150	200
Gaussův šum	7 min	11 min	16 min	22 min	24 min	10 min	17 min	25 min	31 min	36 min	13 min	18 min	27 min	38 min	44 min
Salt&pepper šum	7 min	12 min	15 min	21 min	25 min	11 min	18 min	26 min	32 min	36 min	12 min	19 min	29 min	37 min	42 min
Speckle šum	7 min	12 min	17 min	21 min	26 min	8 min	19 min	26 min	34 min	38 min	14 min	20 min	30 min	38 min	45 min

Po zhodnocení veškerých výpočetních časů bylo zjištěno, že metoda GA dosahuje mnohonásobně vyšších nároků na výpočet. Tento jev je zapříčiněn především nastavením populace a generace, které jsou přímo úměrné s délkou výpočtu. Důležitým krokem je najít kompromis mezi těmito stěžejními parametry pro vyhotovení optimální segmentace. Pokud tedy zvolíme nastavení populace 20 pro 3 shluky, dosáhneme kvalitnějších hodnot v porovnání s KM a FCM, avšak za nižší výpočetní čas.

8 Grafické uživatelské rozhraní

Výše popsané výstupy a analýzy dávají celkový pohled na problematiku metod shlukové analýzy s prvky umělé inteligence. Pokud by si však jakýkoliv nezávislý uživatel chtěl otestovat samotné snímky pro určité nastavení jednotlivých metod, bude pro něho velmi náročné zorientovat se v rozsáhlém zdrojovém kódu. Pro tento účel byla vytvořena aplikace v MATLABu, která je navržena jednoduše pro každého uživatele, tudíž může sloužit zároveň pro testování vybraných snímků či jako edukační pomůcka při výuce zpracování obrazu. Blokový diagram aplikace je zobrazen na Obr. 95.



Obr. 95: Blokový diagram funkčí grafického uživatelského rozhraní [vlastní]

Uživatel má v aplikaci na výběr načíst jakýkoliv snímek ze svého počítače, tento snímek má možnost ovlivnit jedním ze tří typů šumů o různé intenzitě, následně si vybere metodu, kterou bude chtít daný snímek segmentovat. Po zvolení parametrů populace, generace (iterace) a dodatečného nastavení u metod PSO a GA je možné spustit segmentaci.

Výsledná segmentace se zobrazí vždy v okně pod příslušným názvem metody, přičemž je možné využít všech segmentačních metod a následně porovnat jednotlivé výstupy vizuálně či dle evaluačních parametrů, které se zobrazují pod segmentovaným snímkem. Samozřejmostí je funkce, která jednotlivé výstupy evaluačních metrik a segmentovaných snímků uloží do souboru s příponou typu *.mat*. Uložený soubor je následně možné znovu načíst do prostředí MATLAB a dodatečně zpracovávat či analyzovat.

Okno aplikace je složeno z několika částí, vlevo nahoře je možné na Obr. 96 vidět ovládací panel, na kterém jsou tlačítka pro načtení, zašumění obrazu, uložení segmentace a evaluačních parametrů. Dále je na panelu umístěno výběrové menu pro zvolení typu šumu spolu s textovým oknem, do kterého je možno zadat intenzitu šumu v rozmezí od 0 do 1.

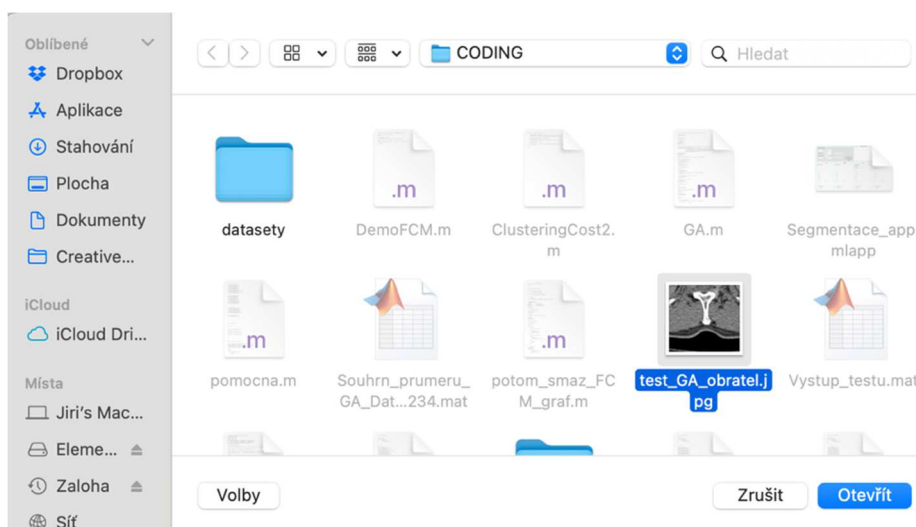


Obr. 96: Grafické uživatelské rozhraní [vlastní]

Vpravo nahoře jsou připravena okna pro jednotlivé snímky, vlevo je okno pro nativní snímek, vpravo pro zašuměný snímek. Spodní část aplikace tvoří panely se všemi testovanými metodami. Před spuštěním segmentace je však nutné zadat u všech metod počet shluků do textových polí umístěných pod názvem každé z metod. GA a PSO navíc disponuje textovým polem pro zadání počtu počáteční populace a výběrovým tlačítkem pro volbu jednoho ze tří dodatečných nastavení. V dolní části jsou umístěna u každé metody dvě tlačítka. První tlačítko *Segmentovat* spustí metodu a následně do šedého pole vedle vypíše evaluační parametry, druhé *Reset* slouží k vymazání parametrů a oken, aby mohla být zvolena nová nastavení segmentace.


8.1 Ovládání aplikace

V první fázi po spuštění aplikace klikneme na tlačítko *Načíst snímek*. Zobrazí se dialogové okno, kde zvolíme libovolný snímek z úložiště v počítači, který se následně automaticky ukáže v okně *Nativní snímek*. Načíst je možno snímek ve formátu .jpg, .png a .tif.



Obr. 97: Dialogové okno umožňující výběr snímku z počítače [vlastní]


V dalším kroku, viz Obr. 98 zvolíme jeden ze tří typů šumu (Gaussův, Salt&pepper, Speckle) pomocí výběrového menu. Do textového pole *Intenzita* zadáme hodnotu v rozmezí od 0 do 1, kde 0 znamená minimální a 1 maximální hodnotu pro zašumění snímku. Po aplikaci šumu se snímek zobrazí v okně zašuměný snímek.



Obr. 98: Ukázka načtení a zašumění snímku [vlastní]

Druhou částí aplikace je provedení samotné segmentace. Uživatel má na výběr ze čtyř metod, viz Obr. 99, po vybrání jedné z metod a zadání potřebných vstupních parametrů je nutno segmentaci spustit tlačítkem *Segmentovat*.

Uživatel si může postupně spustit všechny segmentace za účelem následné komparace, ta je z části viditelná pouhým okem. Pro přesnější analýzu jsou však pod každým se segmentovaným snímek vypsané hodnoty objektivních evaluačních parametrů (CORR, MSE, SSIM, DICE a JACCARD).



Obr. 99: Výsledky všech segmentací spolu se zobrazením evaluačních parametrů [vlastní]

V závěru je možné každé z oken, kde se nachází segmentovaný snímek, resetovat tlačítkem *Reset*. Dojde tak k vymazání příslušného okna spolu s evaluačními parametry. Pokud by uživatel měl zájem dále s parametry a s obrazy pracovat, je možné si je tlačítkem *Uložit evaluace* či *Uložit segmentace* uložit do cílové složky, kde se nachází i aplikace. Obě funkce uloží výsledky do *.mat* souboru, v prvním případě se jedná o hodnoty evaluací a v druhém případě o obrazovou matici s výsledky všech segmentací.

9 Diskuse

Práce se zabývá návrhem a komparativní studií výkonnosti multiregionálních segmentačních metod, které využívají prvky umělé inteligence. Konkrétně se jednalo o metody shlukové analýzy fuzzy c-means (FCM), genetický algoritmus (GA) a evoluční algoritmus (PSO). Celkové testování bylo rozděleno do dvou hlavních částí, přičemž v obou částech byla analýza zaměřena na srovnání s konvenčním algoritmem k-means. Pro testování účinnosti efektivity jednotlivých metod byly použity reálné snímky původem z CT a MRI, na které byl aplikován parazitní šum pro vytvoření variabilních obrazových podmínek. Jednalo se o Gaussův, Salt&pepper a Speckle šum o 20 hodnotách se zvyšující se intenzitou, který byl implementován za účelem sledování dynamiky šumu v kontextu efektivity segmentace.

Z výsledku rozsáhlé analýzy je patrné, že metody s prvky umělé inteligence dosahují mnohem lepších výsledků než konvenční metoda k-means, a to i v závislosti na vyšších hodnotách šumu. Důležitým aspektem je volba testovacích parametrů v závislosti na typu snímků. V rámci robustní analýzy bylo zjištěno, že snímky cév původem z výpočetní tomografie dosahují nejlepších výsledků při nastavení počtu shluků 3, 5 a 7 u všech segmentačních metod. Pokud se však podíváme na snímky CT jater, které vykazují variabilní jasové hodnoty, tak zde je nejlepším nastavením 10 a 12 shluků. V rámci GA, kde bylo mnohem více nastavovaných parametrů, bylo zjištěno, že velikost počáteční populace nemá zásadní vliv na výsledek algoritmu, napříč tomu několikrát násobně zvyšuje výsledný výpočetní čas. Při nastavení populace 20 bylo dosaženo poměrně stejných výsledků jako u populace 200, avšak výpočetní čas zde byl až 4krát vyšší. Analýza zabývající se dodatečným nastavením byla ve většině případech vyhodnocena pro nastavení číslo 2, které zahrnovalo generace v počtu 20, elitní počet 5, frakci křížení 0,5 a stochastickou selekci.

Analýza extrakce tkání jednoznačně ukazuje na robustnost GA a PSO, které dosahují výrazně kvalitnějších výsledků. Pokud se zaměříme na jednotlivé grafy, je u některých z parametrů vidět až o 40 % lepší úspěšnost, než dosahuje metoda k-means. Příčinou je především implementace šumu vyšších intenzit přímo na extrahovanou tkáň. Pokud bychom tedy chtěli segmentovat pouze určitou část snímků, je vhodné zvolit metody s prvky umělé inteligence, a to i na úkor výpočetního času, neboť rozdíl kvality segmentace je zde markantní.

Tato práce může být v budoucnu využita jako edukace či doporučení pro následné zvolení ideálního typu algoritmů, počtu shluků nebo populace na variantní typy šumu. Vylepšením práce by mohla být hybridní metoda s adaptabilním nastavením jednotlivých parametrů v kontextu typu segmentace s redukcí výpočetního času. Dalším krokem této práce je i možnost implementace metod na 3D medicínská obrazová data s možností následné kvalitní extrakce a identifikace tkání.

Závěr

Cílem této práce byla realizace testovacího prostředí pro metody shlukové analýzy v kontextu variabilních obrazových podmínek. V teoretické části byla v počátku popsána samotná segmentace obrazu s jednotlivými principy a zástupci metod. Následně byla rozebrána shluková analýza s několika metodami jak z hierarchické, tak nehierarchické skupiny. Především byl kladen důraz na metodu k-means a fuzzy c-means, které jsou v práci hojně zastoupeny. Součástí práce je také rešeršní část opírající se o zahraniční zdroje popisující současnou situaci segmentace medicínských obrazů v kontextu shlukové analýzy.

K testování byly vybrány konkrétně konvenční metoda KM, následně se již jednalo o metody disponující prvky umělé inteligence FCM, GA a PSO. Všechny metody jsou popsány jak v teoretické, tak v praktické části. U nekonvenčních metod GA a PSO byly názorně ukázány jednotlivé výstupy segmentací společně s grafy zobrazujícími minimalizace rozptylu na základě fitness funkce.

Pro testování byly použity reálné snímky medicínského původu získané z radiodiagnostických metod, konkrétně se jednalo o snímky z výpočetní tomografie a magnetické rezonance. Po načtení obrazové databáze byly snímky převedeny na monochromatický formát a uloženy do buněčného pole pro snazší dávkové testování. Následovala implementace parazitního šumu, jednalo se o Gaussův, Salt&pepper a Speckle šum o 20 intenzitách s rostoucí tendencí, všechny šумы i jejich konkrétní nastavení byly rozebrány v praktické části.

Samotná implementace segmentačních metod i celková analýza byly realizovány v prostředí MATLAB. Celkově bylo vygenerováno přes 150 GB výstupních segmentací. Testování bylo pro zjednodušení rozděleno do dvou hlavních částí, jsou jimi robustní analýza, která testovala metody KM, GA a FCM a extrakce tkání, kde došlo k identifikaci a modelování tkání na základě segmentace, jednalo se především o cévy pořízené v rámci CT angiografie, zde byly implementovány metody KM, FCM, GA a PSO.

V první části testování extrakce tkání bylo na základě objektivních evaluačních parametrů zjištěno, že nejlepších výsledků dosahovala metoda GA, PSO a z části i FCM. Metoda KM v této části vykazovala nejhorší hodnoty parametrů, a to u všech typů snímků a šumů.

Další část věnována robustní analýze, kde byly testovány metody GA, KM a FCM, byla opět jako nejlepší metoda vyhodnocena GA. V rámci některých parametrů, především CORR, docházelo k občasnému vyhodnocení KM jako nejefektivnější, což bylo nejspíše zapříčiněno principem výpočtu parametru, neboť v 90 % případů vychází KM jako nejhorší ze všech metod. V rámci GA algoritmu byly analyzovány počty počáteční populace, kde nebylo jasné ukázáno, že by zvýšení populace rapidně zlepšovalo segmentační model v kontextu variabilních obrazových podmínek. Navíc u analýzy výpočetní náročnosti bylo zjištěno, že se zvyšující se populací rapidně narůstá výpočetní čas. U dodatečného nastavení metody GA bylo stanoveno, že jako nejlepší se jeví nastavení číslo 2.

V závěrečné části této práce bylo vytvořeno grafické uživatelské prostředí, které může sloužit k testování či edukaci. V prostředí bylo možné načíst a zašumět jakýkoliv medicínský snímek a následně vybrat jednu či všechny segmentační techniky. Výsledkem jsou obrazové segmentace a evaluační parametry pro objektivní zhodnocení jednotlivých metod.

Použitá literatura

- [1] KAUR, Manjot a Pratibha GOYAL. A Review on Region Based Segmentation. *International Journal of Science and Research (IJSR)* [online]. Indie, 2015, 4.3.2015, , 3194-3197 [cit. 2020-10-18]. ISSN 2319-7064.
- [2] GARRETA, Raul a Guillermo MONCECCHI. Learning scikit-learn: Machine Learning in Python. Birmingham: Packt Publishing Limited, 2013, 118 s. ISBN 978-1-78328-193-0.
- [3] MITCHELL, Tom M. Machine Learning. New York: McGraw-Hill, c1997. ISBN 978-0070428072.
- [4] HARUŠTIAKOVÁ, Danko. Vícerozměrné statistické metody v biologii. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-791-8.
- [5] HOLČÍK, Jiří. Analýza a klasifikace dat. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-793-2.
- [6] Marhold, K., Suda, J. Statistické zpracování mnohorozměrných dat v taxonomii (Fenologické metody). Učební texty Univerzity Karlovy v Praze. Univerzita Karlova v Praze, Nakladatelství Karolinum. (2002)
- [7] KLÍMEK, Petr. *Shlukovací metody v data miningu: E+M Ekonomie a Management* [online]. 2008, 120-127 [cit. 2018-11-19]. ISSN 1212-3609. Dostupné z: <http://www.ekonomie-management.cz/archiv/vyhledavani/detail/608-shlukovaci-metody-v-data-miningu/>.
- [8] STEINBACH, Michael, George KARYPIS a Vipin KUMAR. A Comparison of Document Clustering Techniques.[online]. University of Minnesota. Dostupné z: <http://glaros.dtc.umn.edu/gkhome/fetch/papers/docclusterKDDTMW00.pdf>.
- [9] GHUMAN, Sukhdev Singh. Clustering Techniques. *International Journal of Computer Science and Mobile Computing*[online]. Indie, 2016, 5.5.2016, 524-530 [cit. 2018-11-22]. ISSN 2320–088X.
- [10] RAMESH, B. a K. NANDHINI. Clustering Algorithms. *International Journal of Computer Sciences and Engineering*[online]. 2017, 30.10.2017, (5), 302-306 [cit. 2020-11-22]. ISSN 2347-2693.
- [11] MELOUN, Milan a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. Vyd. 2., upr. a rozš. Praha: Academia, 2004. ISBN 80-200-1254-0.
- [12] ŘEZANKOVÁ, Hana, Dušan HÚSEK a Václav SNÁŠEL. *Shluková analýza dat*. Praha: Professional Publishing, 2007. ISBN 978-80-86946-26-9.
- [13] ABONYI, Janos a Balázs FEIL. *Cluster analysis for data mining and system identification*. Boston: Birkhäuser, c2007. ISBN 978-3764379872.
- [14] EVERITT, Brian. [i]Cluster analysis.[/i] 5th ed. Chichester, West Sussex, U.K.: Wiley, 2011. Wiley series in probability and statistics. ISBN 978-0-470-74991-3.

- [15] Holčík J, Komenda M (eds.) a kol. *Matematická biologie: e-learningová učebnice* [online]. 1. vydání. Masarykova univerzita [2015]. Dostupný z WWW: <http://portal.matematickabiologie.cz>. ISBN 978-80-210-8095-9.
- [16] WALNER, Jake. *Clustering RNAseq data using fuzzy c-means clustering* [online]. 31.7.2018 [cit. 2020-12-19]. Dostupné z: <https://2-bitbio.com/post/clustering-rnaseq-data-using-fuzzy-c-means-clustering/>
- [17] KAUFMAN, Leonard a Peter J. ROUSSEEUW. *Finding groups in data: an introduction to cluster analysis*. New York: Wiley, c1990. ISBN 9780471878766.
- [18] KUČERA, Jiří. Shluková analýza [online]. 2009 [cit. 2018-02-12]. Dostupné z: <http://aplikacergsg.sci.muni.cz/teorie/doprava/vicerozmerne-statisticke-metody-2>
- [19] LEISCH, Friedrich. Bagged Clustering. *Working Paper Series*. Augasse 2–6, 1090 Wien, Austria, 1999, (51).
- [20] JIRKOVSKÝ, Jaroslav. Strojové učení a prostředí MATLAB. In: *Humusoft* [online]. 2018 [cit. 2018-12-20]. Dostupné z: <https://www.humusoft.cz/blog/20180817-strojove-uceni/>
- [21] BARBU, Tudor. Variational Image Denoising Approach with Diffusion Porous Media Flow. *Abstract and Applied Analysis* [online]. 2013, 1-8 [cit. 2020-03-08]. DOI: 10.1155/2013/856876. ISSN 1085-3375. Dostupné z: <http://www.hindawi.com/journals/aaa/2013/856876/>
- [22] TOH, K.K.V. a N.A.M. ISA. Noise Adaptive Fuzzy Switching Median Filter for Salt-and-Pepper Noise Reduction. *IEEE Signal Processing Letters* [online]. 2010, **17**(3), 281-284 [cit. 2020-03-08]. DOI: 10.1109/LSP.2009.2038769. ISSN 1070-9908. Dostupné z: <http://ieeexplore.ieee.org/document/5356178/>
- [23] HUA, Cheng a Tian JINWEN. Speckle Reduction of Synthetic Aperture Radar Images Based on Fuzzy Logic. In: *2009 First International Workshop on Education Technology and Computer Science* [online]. IEEE, 2009, 2009, s. 933-937 [cit. 2020-03-08]. DOI: 10.1109/ETCS.2009.212. ISBN 978-0-7695-3557-9. Dostupné z: <http://ieeexplore.ieee.org/document/4958916/>
- [24] Charrad, Malika, Nadia Ghazzali, Véronique Boiteau a Azam Niknafs. 2014. „NbClust: Balíček R pro určení relevantního počtu klastrů v datové sadě.“ *Žurnál statistického softwaru* 61: 1–36. <http://www.jstatsoft.org/v61/i06/paper> .
- [25] Thresholding. In: Scikit-image development team [online]. [cit. 2020-11-05]. Dostupné z: https://scikit-image.org/docs/0.13.x/auto_examples/xx_applications/plot_thresholding.html#id4
- [26] KUBÍKOVÁ, Kristýna. *Metody detekce hran v biomedicínských obrazech* [online]. Ostrava, 2019 [cit. 2020-11-05]. Dostupné z: <http://hdl.handle.net/10084/136207>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.

- [27] HLAVÁČ, Václav. Hledání hran a hranových bodů. České vysoké učení technické v Praze: Český institut informatiky, robotiky a kybernetiky [online]. s. 1-48 [cit. 2020-11-05]. Dostupné z: <http://people.ciirc.cvut.cz/~hlavac/TeachPresCz/11DigZprObr/22EdgeDetectionCz.pdf>
- [28] SINGHAL, Akshay. K-means Clustering Algorithm Examples [online]. Gate Vidyalay [cit. 2020-11-05]. Dostupné z: <https://www.gatevidyalay.com/k-means-clustering-algorithm-example/>
- [29] STEINBACH, Michael a Kumar VIPIN. Cluster Analysis: Basic Concepts and Algorithms. Introduction to Data Mining[online]. 2005, s. 487-568 [cit. 2020-11-11]. Dostupné z: <https://www-users.cs.umn.edu/~kumar001/dmbook/ch8.pdf>
- [30] PATEL, Dharmesh. Fuzzy c-means clustering for image segmentation [online]. 11.5.2010, , 1-9 [cit. 2020-11-11]. Dostupné z: <https://www.slideshare.net/pateldharmesh/fuzzy-cmeans-clustering-for-image-segmentation>
- [31] ÜNLER, Apler a Zülal GÜNGÖR. K-Harmonic means data clustering with tabu-search method. Science Direct [online]. 21.4.2007, , 1115-1125 [cit. 2020-11-11]. Dostupné z: www.elsevier.com/locate/apm
- [32] KAUFMAN, Leonard a Peter J. ROUSSEUW, ed. Finding Groups in Data [online]. Hoboken, NJ, USA: John Wiley, 1990 [cit. 2020-11-11]. Wiley Series in Probability and Statistics. ISBN 9780470316801. Dostupné z: doi:10.1002/9780470316801
- [33] MIRKIN, B. G. Clustering for data mining: a data recovery approach. Boca Raton, FL: Chapman & Hall/CRC, 2005. Series in computer science and data analysis, 3. ISBN 1-58488-534-3.
- [34] RIVERA-BORROTO, Oscar Miguel, Mónica RABASSA-GUTIÉRREZ, Ricardo del Corazón GRAU-ÁBALO, Yovani MARRERO-PONCE a José Manuel GARCÍA-DE LA VEGA. Dunn's index for cluster tendency assessment of pharmacological data sets. *Canadian Journal of Physiology and Pharmacology* [online]. 2012, 90(4), 425-433 [cit. 2020-11-11]. ISSN 0008-4212. Dostupné z: doi:10.1139/y2012-002
- [35] ZEEBAREE, Diyar Qader, Habibollah HARON, Adnan Mohsin ABDULAZEEZ a Subhi R. M. ZEEBAREE. Combination of K-means clustering with Genetic Algorithm: A review. *International Journal of Applied Engineering Research*. Indie: Research India Publications, 2017, 2017(12), 14238-14245. ISSN 0973-4562.
- [36] EIBEN, A. E. a J. E. SMITH. Introduction to Evolutionary Computing [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003 [cit. 2020-04-23]. Natural Computing Series. DOI: 10.1007/978-3-662-05094-1. ISBN 978-3-642-07285-7.
- [37] SHYALIKA, Chathurangi. Genetic Algorithms -Selection [online]. 29.1.2019 [cit. 2020-11-11]. Dostupné z: <https://medium.com/datadriveninvestor/genetic-algorithms-selection-5634cfc45d78>
- [38] SHARMA, Tarun Kumar, Millie PANT a V.P SINGH. Improved Local Search in Artificial Bee Colony using Golden Section Search [online]. Indian Institute of Technology Roorkee, Roorkee, India [cit. 2020-11-11].

- [39] KARABOGA, D. a B. BASTURK. On the performance of artificial bee colony (ABC) algorithm [online]. Turecko: Erciyes University, Engineering Faculty, Computer Engineering Department, TR-38039 Kayseri, Turkey, 2008, , 687–697 [cit. 2020-11-11]. Dostupné z: <https://www.sciencedirect.com/sdfe/reader/pii/S1568494607000531/pdf>
- [40] DALLAKI, Hedayatollah, Kimia Bazargan LARI, Ali HAMZEH, Sattar HASHEMI a Ashkan SAMI. Scaling up the hybrid Particle Swarm Optimization algorithm for nominal data-sets. *Intelligent Data Analysis*[online]. 2015, 19(4), 825-844 [cit. 2020-11-11]. ISSN 1088467X. Dostupné z: doi:10.3233/IDA-150747
- [41] GKAI DATZIS, Paschalis, Aggelos BOUHOURAS, Kallisthenis SGOURAS, Dimitrios DOUKAS, Georgios CHRISTOFORIDIS a Dimitris LABRIDIS. Efficient RES Penetration under Optimal Distributed Generation Placement Approach. *Energies* [online]. 2019, 12(7) [cit. 2020-11-11]. ISSN 1996-1073. Dostupné z: doi:10.3390/en12071250
- [42] XU, Xiangping, Jun LI, MengChu ZHOU, Jun XU a Jinde CAO. Accelerated Two-Stage Particle Swarm Optimization for Clustering Not-Well-Separated Data. *IEEE Transactions on Systems, Man, and Cybernetics: Systems* [online]. 2020, 50(11), 4212-4223 [cit. 2020-11-11]. ISSN 2168-2216. Dostupné z: doi:10.1109/TSMC.2018.2839618
- [43] HANČAROVÁ, Kristýna. Moderní metody segmentace obrazu s využitím prvků umělé inteligence[online]. Ostrava, 2020 [cit. 2020-11-11]. Dostupné z: <http://hdl.handle.net/10084/140446>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [44] PIECH, Chris. K Means: The Basic Idea [online]. Stanford, 2013 [cit. 2020-11-11]. Dostupné z: <https://stanford.edu/~cpiech/cs221/handouts/kmeans.html>
- [45] AMANPREET, Kaur a M.D SINGH. An Overview of PSO- Based Approaches in Image Segmentation. *International Journal of Engineering and Technology* [online]. Department of Electrical and Instrumentation Engineering, Thapar University, Patiala, 2012, 8.8.2012 [cit. 2021-03-21]. ISSN 2049-3444.
- [46] SHETA, Alaa, Malik S. BRAIK a Sultan ALJAH DALI. Genetic Algorithms: A Tool for Image Segmentation [online]. 2012 [cit. 2021-03-21]. Dostupné z: http://aljahdali.net/121020162738.pdf?fbclid=IwAR0QMenECesmdn165YyOkpLk_A1iSExFrKkNvnfiQ9UCrJrluCk4sXPLfWU
- [47] TIU, Ekin. Metrics to Evaluate your Semantic Segmentation Model [online]. In: . Stanford, 2019, 10.8.2019 [cit. 2021-03-27]. Dostupné z: <https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2>
- [48] BRUCE, Eugene N. *Biomedical signal processing and signal modeling*. New York: Wiley, c2001. Wiley series in telecommunications and signal processing. ISBN 0-471-34540-7.
- [49] MIRKIN, Boris G. *Clustering for data mining: a data recovery approach*. Boca Raton: Chapman & Hall/CRC, 2005. Computer science and data analysis series. ISBN 1-58488-534-3.

- [50] NILSSON, Nils J. *Artificial intelligence: a new synthesis*. San Francisco: Morgan Kaufmann, c1998. ISBN 1-55860-467-7.
- [51] RUSSELL, Stuart J. a Peter NORVIG. *Artificial intelligence: a modern approach*. 3rd ed., Pearson new international ed. Harlow: Pearson, c2014. ISBN 978-1-292-02420-2.
- [52] SURI, Jasjit S., David L. WILSON a Swamy LAXMINARAYAN, eds. *Handbook of biomedical image analysis*. Volume I, Segmentation Models. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48550-8.

Seznam příloh

I–VI Celková analýza evaluačních hodnot pro jednotlivé datasety:

Příloha I–VI obsahuje tabulky průměrných hodnot analýzy podobnosti pro všechny databáze včetně souhrnné tabulky a analýzy podobnosti ze všech testovaných snímků.

Přílohy na online uložišti:

Součástí této diplomové práce je také příloha, která obsahuje všechny výstupy této diplomové práce o celkové velikosti 170 GB. Součástí složky je hlavičkový soubor popisující jednotlivé soubory uvnitř. Složka byla pro zjednodušení vzhledem ke kapacitě nahrána na online uložišť s následujícím odkazem:

<https://www.dropbox.com/sh/mdma7nukpl06eew/AAA5eZ91HmMOB9qmCWHFckHba?dl=0>

Testovane_snimky

Složka obsahuje ukázkou jednotlivých snímků, které byly testovány v této diplomové práci.

GUI

V rámci této práce bylo vytvořeno grafické uživatelské prostředí, které je součástí příloh a je popsáno hlavičkovým souborem. Prostředí slouží k testování a analýze všech segmentačních metod a šumů. Ve složce je uložena aplikace spolu se všemi potřebnými zdrojovými kódy a jedním snímkem.

Kody_a_Algoritmy

V této složce se nachází veškeré kódy použité pro tuto diplomovou práci. Jedná se hlavně o aplikace šumu, aplikace segmentačních metod a poté i následné vyhodnocení na základě evaluačních parametrů. Všechny soubory ve složce jsou popsány hlavičkovým souborem.

Segmentace_mat

V této složce jsou veškeré datové výstupy jednotlivých segmentací a evaluací náležící k diplomové práci. Výstupy segmentací pocházejí se softwaru MATLAB a jsou uloženy v souborech typu *.mat*. Současně pro zjednodušení byly tyto jednotlivé soubory popsány systémem, který uživateli umožní se ve výstupech jednoduše vyznat a je součástí hlavičkového souboru.

Graficke_vysledky_analyz

V této složce jsou dodatečně uloženy výstupy jednotlivých grafických analýz, které vzhledem k počtu výsledků nemohou být součástí této práce.

I–VI Celková analýza evaluačních hodnot pro jednotlivé datasety

Průměrné hodnoty evaluačních parametrů pro dataset 1 a Gaussův šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Gaussův	GA	3	0,7300	0,7766	0,6423	0,2322	0,0165
		5	0,7600	0,5019	0,3589	0,2428	0,0130
		7	0,7800	0,5362	0,3897	0,2679	0,0151
		10	0,7800	0,5593	0,4114	0,2898	0,0130
		12	0,7900	0,4517	0,3230	0,3021	0,0159
	KM	3	0,6100	0,6266	0,5283	0,1602	0,2699
		5	0,8100	0,6592	0,5503	0,1771	0,3781
		7	0,8300	0,4205	0,3372	0,1912	0,9469
		10	0,8500	0,4254	0,3415	0,1996	1,6206
		12	0,8600	0,3564	0,2862	0,2022	2,1645
	FCM	3	0,7200	0,8530	0,7554	0,1609	0,1763
		5	0,7900	0,6268	0,5179	0,1774	0,4866
		7	0,7900	0,3005	0,2303	0,1903	1,5730
		10	0,8100	0,3469	0,2757	0,2006	2,9123
		12	0,8200	0,2648	0,1987	0,2092	2,4504

Průměrné hodnoty evaluačních parametrů pro dataset 2 a Gaussův šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Gaussův	GA	3	0,9400	0,9632	0,9292	0,6900	0,0065
		5	0,9100	0,8803	0,7891	0,3262	0,0105
		7	0,9200	0,8635	0,7636	0,3530	0,0098
		10	0,9300	0,9283	0,8673	0,4077	0,0076
		12	0,9300	0,9390	0,8863	0,4134	0,0084
	KM	3	0,9400	0,9122	0,8436	0,6259	0,0615
		5	0,9400	0,6402	0,5113	0,2349	0,3061
		7	0,9500	0,5425	0,4123	0,2567	0,4756
		10	0,9600	0,3743	0,2749	0,2771	1,0317
		12	0,9600	0,3375	0,2471	0,2890	1,3632
	FCM	3	0,9400	0,9119	0,8431	0,5954	0,0623
		5	0,9300	0,6660	0,5374	0,2404	0,3224
		7	0,9500	0,5601	0,4287	0,2679	0,5766
		10	0,9500	0,4344	0,3209	0,2927	1,2735
		12	0,9600	0,3301	0,2422	0,3091	1,2987

Průměrné hodnoty evaluačních parametrů pro dataset 3 a Gaussův šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Gaussův	GA	3	0,9600	0,9722	0,9461	0,8197	0,0043
		5	0,8900	0,9527	0,9103	0,2718	0,0117
		7	0,8900	0,9061	0,8302	0,2935	0,0144
		10	0,9100	0,9037	0,8267	0,3211	0,0137
		12	0,9200	0,8988	0,8203	0,3355	0,0128
	KM	3	0,9600	0,9009	0,8308	0,7918	0,0412
		5	0,9400	0,6663	0,5415	0,1971	0,2603
		7	0,9500	0,4904	0,3791	0,2172	0,5516
		10	0,9500	0,3390	0,2550	0,2288	1,2239
		12	0,9600	0,3099	0,2332	0,2338	1,6733
	FCM	3	0,9600	0,9056	0,8378	0,7694	0,0397
		5	0,9300	0,6449	0,5189	0,1947	0,3162
		7	0,9300	0,4301	0,3298	0,2134	0,8959
		10	0,9300	0,2538	0,1952	0,2233	2,2679
		12	0,9400	0,2781	0,2102	0,2335	1,9819

Průměrné hodnoty evaluačních parametrů pro dataset 4 a Gaussův šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Gaussův	GA	3	0,6500	0,6888	0,5375	0,2154	0,0236
		5	0,6700	0,4532	0,3212	0,2162	0,0199
		7	0,7000	0,5038	0,3634	0,2354	0,0199
		10	0,7100	0,4570	0,3277	0,2461	0,0214
		12	0,7200	0,4305	0,3030	0,2553	0,0196
	KM	3	0,6400	0,7967	0,6890	0,1808	0,2459
		5	0,7300	0,5243	0,4052	0,1707	0,6039
		7	0,7600	0,3734	0,2801	0,1812	1,3111
		10	0,7900	0,3018	0,2315	0,1841	2,4832
		12	0,8100	0,3117	0,2361	0,1881	3,1161
	FCM	3	0,6300	0,7946	0,6850	0,1772	0,2570
		5	0,7100	0,4769	0,3673	0,1662	0,8511
		7	0,7200	0,3381	0,2557	0,1777	1,8289
		10	0,7400	0,2624	0,2057	0,1794	3,9794
		12	0,7300	0,2098	0,1662	0,1981	2,0914

Průměrné hodnoty evaluačních parametrů pro dataset 1 a Salt&pepper šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Salt&pepper	GA	3	0,7200	0,7566	0,6623	0,2622	0,0125
		5	0,7400	0,5119	0,3789	0,2628	0,0140
		7	0,7600	0,5262	0,3997	0,2779	0,0135
		10	0,7600	0,5693	0,4314	0,2998	0,0140
		12	0,7700	0,4817	0,3430	0,3121	0,0129
	KM	3	0,6200	0,6166	0,5183	0,1502	0,2999
		5	0,8100	0,6292	0,5203	0,1671	0,3981
		7	0,8200	0,4105	0,3172	0,1812	0,9669
		10	0,8400	0,4154	0,3315	0,1896	1,7206
		12	0,8500	0,3464	0,2662	0,1922	2,3645
	FCM	3	0,7100	0,8230	0,7354	0,1409	0,1863
		5	0,7400	0,6168	0,5279	0,1574	0,5866
		7	0,7200	0,2805	0,2503	0,1403	1,6730
		10	0,8200	0,3169	0,2257	0,1906	2,8123
		12	0,8000	0,2678	0,1687	0,1892	2,6504

Průměrné hodnoty evaluačních parametrů pro dataset 2 a Salt&pepper šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Salt&pepper	GA	3	0,8516	0,9273	0,8665	0,3033	0,0177
		5	0,8694	0,8698	0,7747	0,3056	0,0117
		7	0,8799	0,8873	0,8016	0,3451	0,0098
		10	0,8805	0,8692	0,7761	0,3518	0,0093
		12	0,8824	0,8863	0,7996	0,3565	0,0087
	KM	3	0,8517	0,8487	0,7540	0,2082	0,1838
		5	0,8721	0,7935	0,6817	0,2042	0,4034
		7	0,8739	0,7184	0,5979	0,2036	0,7873
		10	0,8872	0,7286	0,6026	0,2142	1,3475
		12	0,8765	0,7262	0,6005	0,2128	2,3419
	FCM	3	0,8504	0,8397	0,7424	0,1997	0,1879
		5	0,8708	0,7788	0,6630	0,1971	0,4249
		7	0,8792	0,7531	0,6317	0,2161	0,8190
		10	0,8865	0,7012	0,5704	0,2088	1,3422
		12	0,8845	0,2295	0,2000	0,2080	2,1383

Průměrné hodnoty evaluačních parametrů pro dataset 3 a Salt&pepper šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Salt&pepper	GA	3	0,8518	0,8856	0,7990	0,2721	0,0188
		5	0,8643	0,8766	0,7864	0,2904	0,0113
		7	0,8716	0,8919	0,8092	0,3105	0,0099
		10	0,8736	0,8528	0,7493	0,3165	0,0091
		12	0,8776	0,8941	0,8123	0,3322	0,0082
	KM	3	0,8417	0,7983	0,7293	0,2982	0,8833
		5	0,8424	0,7657	0,6636	0,2242	1,4456
		7	0,8542	0,7165	0,5999	0,2136	1,7845
		10	0,8382	0,7298	0,6322	0,2542	2,3411
		12	0,8335	0,7199	0,6102	0,2383	2,8411
	FCM	3	0,8606	0,8598	0,7345	0,2497	0,1893
		5	0,8508	0,7883	0,6932	0,2391	0,6243
		7	0,8492	0,7435	0,6317	0,2461	0,9191
		10	0,8561	0,7422	0,6209	0,2381	1,8423
		12	0,8548	0,3211	0,2901	0,2700	1,9344

Průměrné hodnoty evaluačních parametrů pro dataset 4 a Salt&pepper šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Salt&pepper	GA	3	0,5910	0,6159	0,5346	0,2978	0,0297
		5	0,7376	0,7510	0,6152	0,3341	0,0143
		7	0,7200	0,6834	0,5344	0,3083	0,0152
		10	0,7080	0,7283	0,5876	0,3171	0,0149
		12	0,7033	0,7412	0,6026	0,3214	0,0149
	KM	3	0,6081	0,8029	0,7266	0,2080	0,1658
		5	0,7000	0,8437	0,7819	0,2384	0,5720
		7	0,6826	0,8750	0,8257	0,2575	1,3014
		10	0,6826	0,8750	0,8257	0,2575	1,3014
		12	0,7000	0,8437	0,7819	0,2384	0,5720
	FCM	3	0,4592	0,5122	0,4242	0,1913	0,3916
		5	0,7046	0,8513	0,7931	0,2340	0,5689
		7	0,7046	0,8513	0,7931	0,2340	0,5689
		10	0,7046	0,8513	0,7931	0,2340	0,5689
		12	0,7046	0,8513	0,7931	0,2340	0,5689

Průměrné hodnoty evaluačních parametrů pro dataset 1 a Speckle šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Speckle	GA	3	0,8145	0,8966	0,9032	0,2975	0,0111
		5	0,8294	0,8119	0,8380	0,2928	0,0134
		7	0,8028	0,8037	0,8103	0,3023	0,0139
		10	0,7927	0,8394	0,8298	0,3134	0,0147
		12	0,8098	0,8013	0,7927	0,3348	0,0160
	KM	3	0,7923	0,6827	0,6928	0,2328	0,3193
		5	0,7625	0,6209	0,6704	0,1937	0,3726
		7	0,8210	0,6023	0,5983	0,1898	0,8373
		10	0,8083	0,5837	0,6012	0,1845	1,0032
		12	0,7823	0,5018	0,4977	0,1965	1,9373
	FCM	3	0,8028	0,8028	0,7927	0,2674	0,1362
		5	0,8011	0,7926	0,7925	0,2575	0,1638
		7	0,7826	0,7763	0,7789	0,2183	0,4352
		10	0,7928	0,7937	0,7826	0,2038	1,0347
		12	0,7602	0,7802	0,7727	0,1993	1,5502

Průměrné hodnoty evaluačních parametrů pro dataset 2 a Speckle šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Speckle	GA	3	0,7852	0,9733	0,7892	0,3922	0,0213
		5	0,7927	0,9437	0,7672	0,3863	0,0437
		7	0,8027	0,9738	0,7982	0,3726	0,0192
		10	0,7736	0,9626	0,8273	0,3920	0,0321
		12	0,7536	0,8927	0,7632	0,4035	0,0093
	KM	3	0,6762	0,8927	0,6539	0,4038	0,1120
		5	0,6826	0,8632	0,6488	0,4182	0,2653
		7	0,7273	0,8826	0,6726	0,4382	0,8873
		10	0,7103	0,9028	0,6402	0,4028	1,2103
		12	0,6928	0,8527	0,7028	0,3827	1,9434
	FCM	3	0,7904	0,9763	0,7421	0,1997	0,1226
		5	0,7733	0,9873	0,7645	0,1971	0,1847
		7	0,7632	0,9536	0,7836	0,2161	0,7990
		10	0,8234	0,9433	0,7320	0,2088	1,1012
		12	0,8166	0,8837	0,7173	0,2080	1,5822

Průměrné hodnoty evaluačních parametrů pro dataset 3 a Speckle šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Speckle	GA	3	0,8890	0,8723	0,7609	0,2902	0,0123
		5	0,8793	0,8794	0,7881	0,2934	0,0151
		7	0,8903	0,7937	0,7934	0,3349	0,0112
		10	0,8612	0,8349	0,7411	0,3284	0,0187
		12	0,8567	0,8883	0,8363	0,3637	0,0132
	KM	3	0,8349	0,8224	0,7530	0,1983	0,1621
		5	0,8182	0,8004	0,6909	0,1833	0,3074
		7	0,8438	0,8175	0,7023	0,2304	0,5328
		10	0,7932	0,7682	0,7145	0,2199	0,9495
		12	0,8313	0,7893	0,6582	0,2220	1,3419
	FCM	3	0,8753	0,8934	0,7638	0,2432	0,1978
		5	0,8858	0,9002	0,7323	0,2342	0,1299
		7	0,8973	0,8633	0,7193	0,2207	0,2190
		10	0,8575	0,8372	0,7490	0,2884	0,1622
		12	0,8738	0,8583	0,7938	0,2638	1,0083

Průměrné hodnoty evaluačních parametrů pro dataset 4 a Speckle šum							
Typ šumu	Metoda	Počet shluků	CORR	DICE	JACCARD	SSIM	MSE
Speckle	GA	3	0,6310	0,9065	0,7738	0,3198	0,0205
		5	0,7536	0,8520	0,7392	0,3445	0,0101
		7	0,7400	0,7877	0,7244	0,3294	0,0193
		10	0,7530	0,7283	0,7099	0,3391	0,0165
		12	0,6123	0,7364	0,7021	0,3023	0,0145
	KM	3	0,6246	0,8631	0,6923	0,2290	0,1703
		5	0,7130	0,7490	0,6793	0,2312	0,6789
		7	0,6324	0,7250	0,6932	0,2209	1,2038
		10	0,6699	0,7141	0,6599	0,2267	1,4014
		12	0,5927	0,6939	0,6343	0,2454	0,7922
	FCM	3	0,6594	0,9122	0,7623	0,2012	0,5933
		5	0,7298	0,8445	0,7483	0,2466	0,5832
		7	0,7276	0,7941	0,7929	0,2462	0,5411
		10	0,7391	0,7033	0,8001	0,2299	0,5799
		12	0,7014	0,7233	0,7810	0,2405	0,5574